

Comité de Normas Técnicas de la OMPI (CWS)

**Cuarta sesión
Ginebra, 12 a 16 de mayo de 2014**

NUEVA NORMA DE LA OMPI SOBRE LA PRESENTACIÓN DE LISTAS DE SECUENCIAS DE NUCLEÓTIDOS Y AMINOÁCIDOS EN LENGUAJE EXTENSIBLE DE MARCADO (XML)

Documento preparado por la Secretaría

1. El Comité de Normas Técnicas de la OMPI (CWS), en su primera sesión, celebrada en octubre de 2010, acordó crear la Tarea N° 44 relativa a la preparación de recomendaciones sobre la presentación de listas de secuencias de nucleótidos y aminoácidos en lenguaje extensible de marcado (XML) para su adopción como norma técnica de la OMPI. Asimismo, el CWS decidió establecer un equipo técnico que se ocupara de esa tarea (Equipo Técnico SEQL). La Oficina Europea de Patentes (EPO) fue designada responsable del Equipo Técnico. (Véanse los párrafos 27 a 30 del documento CWS/1/10, la Tarea N° 44 del documento CWS/3/12, la descripción de la tarea se proporciona igualmente en el Anexo I del presente documento.)
2. A raíz de la mencionada decisión del CWS, se designó a representantes de 13 oficinas de propiedad industrial (OPI) y a la Oficina Internacional para que participaran en el Equipo Técnico. En su segunda y tercera sesiones, el CWS tomó nota de la información que la OEP, en calidad de responsable del Equipo Técnico, proporcionó sobre la situación de los debates del Equipo Técnico SEQL, entre los que figuraba el plan de trabajo para la preparación de las recomendaciones. (Véanse los documentos CWS/2/5 y CWS/3/6.)
3. Tras la tercera sesión del CWS, el Equipo Técnico SEQL prosiguió los debates en el foro Wiki. En el Anexo I del presente documento se reproduce el informe elaborado por el responsable del Equipo Técnico sobre la labor realizada por el Equipo Técnico.
4. A raíz de la mencionada petición del CWS, el Equipo Técnico SEQL ha preparado una propuesta de nueva norma a fin de que sea examinada y aprobada por el CWS. La denominación propuesta para la nueva norma es “Norma S.T.26 de la OMPI – Norma

recomendada para la presentación de listas de secuencias de nucleótidos y aminoácidos en lenguaje extensible de marcado (XML)". En el Anexo II del presente documento se reproduce el proyecto de nueva Norma ST.26 de la OMPI, que contiene el cuerpo principal y cinco anexos.

5. El CWS pidió asimismo al Equipo Técnico SEQL que se coordinara con el órgano pertinente del PCT en relación con la posible incidencia de la nueva Norma ST.26 en el Anexo C de las Instrucciones Administrativas del PCT (véase el párrafo 29.c) del documento CWS/1/10). Los miembros del Equipo Técnico están examinando actualmente las disposiciones relativas a la transición de la Norma ST.25 de la OMPI a la nueva Norma ST.26 de la OMPI. Está previsto presentar esas disposiciones al CWS a fin de que las examine en su siguiente sesión, que se celebrará en 2015 (véase el párrafo 10 "Plan de trabajo" del Anexo I del presente documento).

6. Se pide a las OPI que aplacen los preparativos para la aplicación de la nueva Norma ST.26 de la OMPI hasta que el CWS apruebe las mencionadas disposiciones relativas a la transición. Mientras tanto, se deberá seguir usando la Norma ST.25. Teniendo esto presente, a condición de que se adopte la nueva norma en la presente (cuarta) sesión del CWS, el Equipo Técnico propone incluir la siguiente Nota editorial en la nueva norma:

"Nota editorial de la Oficina Internacional"

"El CWS acuerda pedir a las oficinas de propiedad industrial que aplacen los preparativos para la aplicación de la nueva Norma ST.26 de la OMPI hasta que el CWS apruebe las recomendaciones para la transición de la Norma ST.25 a la nueva Norma ST.26 en su quinta sesión, que se celebrará en 2015. Mientras tanto, se deberá seguir usando la Norma ST.25.

La Norma se publica a los fines de la información de las oficinas de propiedad industrial y otras partes interesadas.

El Comité de Normas Técnicas de la OMPI (CWS) aprobó la presente norma en su [cuarta sesión, el 16 de mayo de 2014]."

7. *Se invita al CWS a:*

a) *tomar nota del informe de situación relativo a la labor del Equipo Técnico SEQL proporcionado en el Anexo I del presente documento;*

b) *aprobar como denominación de la norma propuesta la de "Norma ST.26 de la OMPI – Norma recomendada para la presentación de listas de secuencias de nucleótidos y aminoácidos en lenguaje extensible de marcado (XML)";*

c) *considerar y aprobar la Norma ST.26 de la OMPI, reproducida en el Anexo II del presente documento;*

d) *considerar y aprobar la Nota editorial que ha de incluirse en la*

Norma ST.26 de la OMPI (véase el párrafo 6, supra); y

e) pedir al Equipo Técnico SEQL que prepare una propuesta de disposiciones transitorias, según lo mencionado en el párrafo 5, supra, y las someta a examen y aprobación del CWS en su quinta sesión.

[Siguen los Anexos]

INFORME SOBRE LA PREPARACIÓN DE UNA NUEVA NORMA TÉCNICA DE LA OMPI RELATIVA A LA PRESENTACIÓN DE LISTAS DE SECUENCIAS DE NUCLEÓTIDOS Y AMINOÁCIDOS MEDIANTE EL LENGUAJE EXTENSIBLE DE MARCADO (XML)

Documento preparado por la Oficina Europea de Patentes (OEP)

ANTECEDENTES

1. En su primera sesión (25 a 29 de octubre de 2010), el Comité de Normas Técnicas de la OMPI (CWS) constituyó el Equipo Técnico sobre listas de secuencias encargado de elaborar la Tarea N° 44 (véase el párrafo 29 del documento CWS/1/10):

“Preparar una recomendación sobre la presentación de listas de secuencias de nucleótidos y aminoácidos en lenguaje extensible de marcado (XML) para su adopción como norma técnica de la OMPI. Además de la propuesta de una nueva norma técnica de la OMPI, debe presentarse un informe sobre el efecto de dicha norma en la actual Norma ST.25 de la OMPI, además de los cambios necesarios propuestos de dicha Norma ST.25.”

2. Asimismo, se pidió al Equipo Técnico que:

“establezca contacto con el órgano pertinente del PCT teniendo en cuenta la posible incidencia de la nueva norma en el Anexo C de las Instrucciones Administrativas del PCT”.

3. Se asignó a la Oficina Europea de Patentes (OEP) la función de responsable del Equipo Técnico y desde entonces se han celebrado seis rondas de debates en el espacio wiki de la OMPI y se ha presentado un proyecto final a consulta pública. Se llegó a un acuerdo sobre el principio de diferenciar los aspectos técnicos de la Norma ST.25 del Anexo C (Instrucciones Administrativas del PCT) en la decimoctava Reunión de las Administraciones Internacionales del PCT en febrero de 2011 (véanse los párrafos 88 a 92 del documento PCT/MIA/18/16) y en la cuarta reunión del Grupo de Trabajo del PCT en junio de 2011 (véanse los párrafos 180 a 188 del documento PCT/WG/4/17).

4. Sobre la base de los comentarios recibidos de los miembros del Equipo Técnico, se celebró una ronda final de debates con el fin de lograr el acuerdo común sobre los requisitos de la Norma.

INFORME SOBRE LA MARCHA DE LA LABOR

5. El Equipo Técnico inició su trabajo en febrero de 2011 basándose en los borradores preparados por la OEP. Muchas Oficinas participaron en el proceso publicando útiles comentarios en el espacio wiki de la OMPI.

6. En marzo de 2012, el Equipo Técnico finalizó un proyecto de norma que pudieran utilizar las oficinas para celebrar consultas con sus usuarios respectivos. Se plantearon varias cuestiones importantes en los comentarios públicos y se han examinado en cooperación con los proveedores de bases de datos DDBJ, EBI, NCBI.

7. La sexta ronda de debates finalizó en septiembre de 2013 y el proyecto que incorporaba las mejoras resultantes de la consulta pública y los debates ulteriores entre los miembros del Equipo Técnico y los proveedores de bases de datos se publicó en el espacio wiki de la OMPI para su examen final.

8. Sobre la base de los comentarios recibidos de los miembros del Equipo Técnico, se celebró una ronda final de debates con el fin de lograr el acuerdo común sobre los requisitos de la Norma. De modo provisional, el Equipo Técnico utilizó la denominación Norma ST.26 para esa norma. Se han introducido las mejoras siguientes en el cuerpo principal y en los anexos propuestos por el Equipo Técnico a fin de que sean examinadas y aprobadas por el CWS:

- a) Todas las cuestiones de procedimiento (PCT) se transfieren a las Instrucciones Administrativas del PCT: la nueva norma tratará únicamente de aspectos técnicos que permiten una presentación óptima de las listas de secuencias (la parte relacionada con la biotecnología) y el formato adecuado de la presentación (XML).
- b) Se ha mejorado considerablemente la parte relacionada con la biotecnología a fin de reflejar las normas vigentes en dicho sector, por ejemplo:
 - inclusión de nucleótidos y aminoácidos modificados no contemplados previamente (por ejemplo, D-aminoácidos, ácidos nucleicos péptidos, morfolinos, etc.) que al haber cobrado importancia en el sector tienen que poder buscarse electrónicamente;
 - Instrucciones precisas para las secuencias con espacios y las variantes de secuencias;
 - aclaraciones con respecto a características y anotaciones;
 - coherencia con los requisitos de los consorcios públicos más recientes de bancos de secuencias biológicas (INSDC y Uniprot); y
 - la definición de XML será completa y no dependerá de la Norma ST.36 ni de la Norma ST.96.
- c) La sintaxis proporcionada por la definición de tipo de documento (DTD) utilizada en la Norma ST.26 fomenta la exactitud de los datos y permite efectuar automáticamente el control de calidad.

9. El Equipo Técnico seguirá trabajando en los aspectos relativos a la transición en 2014 y 2015 con el objetivo de someter a consideración y aprobación del CWS, en su quinta sesión, las recomendaciones para la transición de la Norma ST.25 a la Norma ST.26.

PLAN DE TRABAJO

10. Después de la cuarta sesión del CWS tendrá lugar una nueva ronda de debates, centrados en la preparación de las recomendaciones relativas a la fase de transición que se han de presentar en la sesión del CWS en 2015.

[Sigue el Anexo II]

NORMA ST.26

NORMA RECOMENDADA PARA LA PRESENTACIÓN DE LISTAS DE SECUENCIAS DE NUCLEÓTIDOS Y AMINOÁCIDOS MEDIANTE EL LENGUAJE EXTENSIBLE DE MARCADO (XML)

Proyecto final

Propuesta presentada por el Equipo Técnico SEQL para examen y aprobación por el CWS/4

ÍNDICE

INTRODUCCIÓN	2
DEFINICIONES.....	2
ÁMBITO	3
REFERENCIAS.....	3
PRESENTACIÓN DE SECUENCIAS	3
<i>Secuencias de nucleótidos.....</i>	3
<i>Secuencias de aminoácidos.....</i>	5
<i>Presentación de casos especiales</i>	7
ESTRUCTURA DE LA LISTA DE SECUENCIAS EN FORMATO XML	7
<i>Elemento raíz.....</i>	8
<i>Parte de información general</i>	9
<i>Parte de datos de secuencia</i>	12
<i>Cuadro de características.....</i>	14
<i>Claves de caracterización</i>	14
<i>Claves de caracterización obligatorias</i>	14
<i>Localización de característica.....</i>	14
<i>Calificadores de caracterización.....</i>	16
<i>Calificadores de caracterización obligatorios.....</i>	17
<i>Elementos de los calificadores</i>	17
<i>Texto libre</i>	19
<i>Secuencias codificadoras.....</i>	19
<i>Variantes.....</i>	19

ANEXOS

Anexo I - Vocabulario controlado

Anexo II - Definiciones de tipo de documento (DTD) para las listas de secuencias

Anexo III - Ejemplo de lista de secuencias (archivo XML)

Anexo IV - Subconjunto de caracteres de la tabla de códigos de caracteres del alfabeto latino básico de la norma Unicode

Anexo V - Requisitos adicionales sobre el intercambio datos (únicamente para las oficinas de patentes)

NORMA ST.26

NORMA RECOMENDADA PARA LA PRESENTACIÓN DE LISTAS DE SECUENCIAS DE NUCLEÓTIDOS Y AMINOÁCIDOS MEDIANTE EL LENGUAJE EXTENSIBLE DE MARCADO (XML)

Proyecto final

Propuesta presentada por el Equipo Técnico SEQL para examen y aprobación por el CWS/4

INTRODUCCIÓN

1. Esta Norma define la manera de divulgar en una solicitud de patente las secuencias de nucleótidos y aminoácidos que deben figurar en una lista de secuencias, las características de esas divulgaciones, y la definición de tipo de documento (DTD) cuando las listas de secuencias se presentan en lenguaje extensible de marcado (XML). Se recomienda a las oficinas de propiedad industrial que acepten toda lista de secuencias compatible con esta Norma, que se presente en una solicitud de patente o en relación con una solicitud de patente.

2. La Norma tiene por objetivo:

- a) permitir que el solicitante establezca una única lista de secuencias en una solicitud de patente que sea aceptable a los efectos tanto de los procedimientos internacionales como nacionales o regionales;
- b) mejorar la precisión y calidad de la presentación de las secuencias a fin de facilitar su difusión para beneficio de los solicitantes, el público y los examinadores;
- c) facilitar la búsqueda de datos en las secuencias; y
- d) permitir el intercambio electrónico de datos sobre las secuencias y la introducción de esos datos en bases de datos informatizadas.

DEFINICIONES

3. A los efectos de la presente Norma:

- a) por "aminoácido" se entenderá todo aminoácido que pueda ser representado mediante cualquiera de los símbolos descritos en el Anexo I (véase el Cuadro 3 de la Sección 3). Quedan comprendidos entre tales aminoácidos, los D-aminoácidos y los aminoácidos que contienen cadenas laterales modificadas o sintéticas. Los aminoácidos deberán interpretarse como L-aminoácidos no modificados a menos que se indique con detalle que se trata de aminoácidos modificados tal como se prevé en el párrafo 29.
- b) por "vocabulario controlado" se entenderá la terminología descrita en la presente Norma que deberá utilizarse a la hora de indicar las características de una secuencia, a saber, las anotaciones de regiones o sitios de interés tal como figuran en el Anexo I.
- c) por "secuencia ignorada deliberadamente", o secuencia vacía, se entenderá un espacio reservado para mantener la numeración de las secuencias que figuran en la lista de secuencias a fin de garantizar su coherencia con la numeración de la divulgación, por ejemplo, para no tener que volver a numerar las secuencias contenidas en la divulgación y en la lista de secuencias cuando se suprime una secuencia de la divulgación.
- d) por "nucleótido" se entenderá todo nucleótido o análogo de nucleótido que pueda representarse utilizando cualquiera de los símbolos descritos en el Anexo I (véase el Cuadro 1 de la Sección 1). Los nucleótidos podrán contener, entre otros elementos, una base modificada o sintética de purina o pirimidina, o una ribosa o deoxirribosa modificada o sintética, y podrán unirse mediante un enlace internucleósido modificado o sintético en el sentido de 3' a 5', es decir, toda fracción química que ofrezca la misma función estructural que la fracción fosfato de ADN o ARN, como en el caso de una fracción de fosforotioato.
- e) por "residuo" se entenderá todo nucleótido o aminoácido individual de una secuencia.
- f) por "identificador de secuencia" se entenderá un número entero único que se asigna a cada secuencia de la lista de secuencias.
- g) por "lista de secuencias" se entenderá una parte de la descripción de la solicitud de patente tal como fue presentada, o un documento presentado posteriormente a la solicitud, que presenta la(s) secuencia(s) divulgada(s) de nucleótidos y/o aminoácidos junto con toda otra descripción detallada.
- h) por "específicamente definido" se entenderá todo nucleótido distinto a los representados por el símbolo "n" y todo aminoácido distinto a los representados por el símbolo "X" que se enumeran en el Anexo I.

i) por nucleótido o aminoácido “desconocido” se entenderá la presencia de un único nucleótido o aminoácido cuya identidad es desconocida o no se divulga.

ÁMBITO

4. La presente Norma establece los requisitos de presentación de las listas de secuencias de nucleótidos y aminoácidos de las secuencias divulgadas en las solicitudes de patente.

5. Una lista de secuencias compatible con la presente Norma (en adelante lista de secuencias) contiene una parte de información general y una parte de datos de secuencia. La lista de secuencias deberá presentarse en un único archivo en formato XML utilizando la definición de tipo de documento (DTD) descrita en el Anexo II. El objetivo de la información bibliográfica contenida en la parte de información general sirve únicamente para vincular la lista de secuencias a la solicitud de patente en el marco de la cual se presenta dicha lista de secuencias. La parte de datos de secuencia está compuesta por uno o más elementos de datos de secuencia, cada uno de los cuales contiene información acerca de una secuencia. Los elementos de datos de secuencia incluyen varias claves de caracterización y los calificadores subsiguientes basados en las especificaciones de la *International Nucleotide Sequence Database Collaboration* (INSDC) y UniProt.

6. A los efectos de la presente Norma, una secuencia deberá figurar en una lista de secuencias cuando se divulga en cualquier parte de una solicitud mediante la enumeración de sus residuos y se trata de:

- a) una secuencia no ramificada o una porción lineal de una secuencia ramificada que contiene diez o más nucleótidos específicamente definidos, en la que los nucleótidos adyacentes están unidos en el sentido 3' a 5' (o 5' a 3'), o
- b) una secuencia no ramificada o una porción lineal de una secuencia ramificada que contiene cuatro o más aminoácidos específicamente definidos, en la que los aminoácidos adyacentes están unidos por enlaces peptídicos.

7. Una lista de secuencias no deberá incluir ninguna secuencia que tenga menos de diez nucleótidos específicamente definidos, o menos de cuatro aminoácidos específicamente definidos.

REFERENCIAS

8. Las siguientes Normas y recursos son referencias pertinentes para la presente Norma:

International Nucleotide Sequence Database Collaboration (INSDC)

<http://www.insdc.org/>;

Norma ISO 639-1 - *Codes for the representation of names of languages*

Part 1: Alpha-2 code;

UniProt Consortium

<http://www.uniprot.org/>;

W3C XML 1.0

<http://www.w3.org/>;

Norma técnica de la OMPI [ST.2](#)

Forma normalizada de designar las fechas según el calendario gregoriano;

Norma técnica de la OMPI [ST.3](#)

Códigos normalizados de dos letras, recomendados para la representación de Estados, otras entidades y organizaciones intergubernamentales;

Norma técnica de la OMPI [ST.16](#)

Código normalizado para la identificación de los diferentes tipos de documentos de patente;

Norma técnica de la OMPI [ST.25](#)

Norma para la presentación de listas de secuencias de nucleótidos y aminoácidos en solicitudes de patente.

PRESENTACIÓN DE SECUENCIAS

9. Se asignará a cada secuencia un identificador de secuencia distinto. Los identificadores de secuencias comenzarán con el número 1, e irán aumentando de forma consecutiva por números enteros. Si a un identificador de secuencia no correspondiese una secuencia, a saber, una secuencia ignorada deliberadamente, se utilizará el código “000” en lugar de la secuencia (véase el párrafo 58). El número total de secuencias deberá indicarse en la lista de secuencias y deberá ser igual al número total de identificadores de secuencias, con independencia de si van seguidos de una secuencia o del código “000.”

Secuencias de nucleótidos

10. Toda secuencia de nucleótidos sólo deberá representarse mediante una cadena única, en el sentido 5' a 3' y de izquierda a derecha. Los valores 5' y 3' no deberán aparecer en la secuencia. Toda secuencia de nucleótidos de doble cadena divulgada mediante la enumeración de los residuos de ambas cadenas deberá presentarse de la siguiente manera:

- a) una única secuencia dos secuencias distintas, a las que se les asignará su propio identificador de secuencia, en el que las dos cadenas distintas deberán ser plenamente complementarias entre sí, o

- b) dos secuencias distintas, a las que se les asignará su propio identificador de secuencia, en el que las dos cadenas no son plenamente complementarias entre sí.
11. La numeración de las posiciones de nucleótidos deberá comenzar en la primera base de la secuencia con el número 1. Esa numeración deberá ser continua a lo largo de toda la secuencia en el sentido 5' a 3'.
12. El método de numeración descrito para las secuencias de nucleótidos también es aplicable a las secuencias de nucleótidos de configuración circular. En ese caso, el solicitante deberá elegir el nucleótido en el que comienza la numeración.
13. Todos los nucleótidos de una secuencia deberán representarse mediante los símbolos descritos en el Anexo I (véase el Cuadro 1 de la Sección 1). Se utilizarán únicamente letras minúsculas. Todo símbolo utilizado para representar un nucleótido equivale a un único residuo.
14. El símbolo "t" se interpretará como timina en ADN y uracilo en ARN. El uracilo en ADN o la timina en ARN se considerará como un nucleótido modificado y deberá ir acompañado de una descripción detallada tal como se prevé en el párrafo 18.
15. Si fuera necesario utilizar un símbolo de ambigüedad (que represente dos o más bases alternativas), deberá utilizarse el símbolo más restrictivo. Por ejemplo, si una base en una determinada posición pudiera ser "a" o "g", se utilizará "r", en vez de "n". El símbolo "n" se interpretará como "a", "c", "g", o "t/u", excepto cuando se utilice en una descripción detallada tal como se prevé en los párrafos 16 y 17 o 20. El símbolo "n" no podrá utilizarse para representar un elemento distinto a un nucleótido. El símbolo "n" podrá representar un único nucleótido modificado o "desconocido", junto con una descripción detallada tal como se prevé en los párrafos 16 y 17 o 20.
16. Los nucleótidos modificados deberán representarse en la secuencia como las correspondientes bases no modificadas, a saber, "a", "c", "g" o "t" cuando sea posible. Todo nucleótido modificado en una secuencia que no pueda representarse de otra manera por ningún otro símbolo descrito en el Anexo I (véase el Cuadro 1 de la Sección 1), tales como los nucleótidos que no existen en estado natural, deberá representarse mediante el símbolo "n". Cuando se utiliza el símbolo "n" para representar un nucleótido modificado, éste equivale a un único residuo.
17. Los nucleótidos modificados deberán describirse con detalle en el cuadro de características (véanse los párrafos 59 y siguientes) utilizando la clave de caracterización "modified_base" y el calificador obligatorio "mod_base". El valor calificador deberá corresponder a una abreviatura única que figure en el Anexo I (véase el Cuadro 2 de la Sección 2; si la abreviatura es "OTHER", el nombre completo no abreviado de la base modificada deberá indicarse como valor en un calificador "note". Las abreviaturas (o nombres completos) que figuran en el Anexo I (véase el Cuadro 2 de la Sección 2) a las que se ha referencia *supra* no deberán utilizarse en la propia secuencia.
18. El uracilo en ADN o la timina en ARN se consideran nucleótidos modificados y deberán representarse en la secuencia por una "t" y describirse con detalle en el cuadro de características utilizando la clave de caracterización "modified_base", el calificador "mod_base" con el valor calificador "OTHER" y el calificador "note" con el valor calificador "uracil" o "thymine", respectivamente.
19. Los siguientes ejemplos ilustran la presentación de los nucleótidos modificados en la forma prevista en los párrafos 16 y 17 *supra*:

Ejemplo 1: Nucleótido modificado utilizando una abreviatura que figura en el Anexo I (véase el Cuadro 2 de la Sección 2)

```
<INSDFeature>
  <INSDFeature_key>modified_base</INSDFeature_key>
  <INSDFeature_location>15</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>mod_base</INSDQualifier_name>
      <INSDQualifier_value>i</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

Ejemplo 2: Nucleótido modificado utilizando "OTHER" como figura en el Anexo I (véase el Cuadro 2 de la Sección 2)

```
<INSDFeature>
  <INSDFeature_key>modified_base</INSDFeature_key>
  <INSDFeature_location>4</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>mod_base</INSDQualifier_name>
      <INSDQualifier_value>OTHER</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

```

        <INSDQualifier_name>note</INSDQualifier_name>
        <INSDQualifier_value>xanthine</INSDQualifier_value>
    </INSDQualifier>
</INSDFeature_qual>
</INSDFeature>

```

20. Todo nucleótido “desconocido” deberá representarse mediante el símbolo “n” en la secuencia. Los nucleótidos “desconocidos” deberán describirse con detalle en el cuadro de características (véanse los párrafos 60 siguientes) utilizando la clave de caracterización “unsure”. El símbolo “n” equivale a un único residuo.

21. Toda región que contiene un número conocido de residuos contiguos “a”, “c”, “g”, “t”, o “n” para los cuales se aplica la misma descripción podrá describirse en conjunto utilizando la sintaxis “x.y” como descriptor de localización en el elemento `INSDFeature_location` (véanse los párrafos 65 a 72). Para la presentación de las variantes de secuencia, es decir, supresiones, inserciones o sustituciones, véanse los párrafos 92 a 97.

22. El siguiente ejemplo ilustra la presentación de una región de nucleótidos modificados para los cuales se aplica la misma descripción en la forma prevista en el párrafo 21 *supra*:

```

<INSDFeature>
  <INSDFeature_key>modified_base</INSDFeature_key>
  <INSDFeature_location>358..485</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>mod_base</INSDQualifier_name>
      <INSDQualifier_value>OTHER</INSDQualifier_value>
    </INSDQualifier>
    <INSDQualifier>
      <INSDQualifier_name>note</INSDQualifier_name>
      <INSDQualifier_value>isoguanine</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>

```

Secuencias de aminoácidos

23. Los aminoácidos de una secuencia proteínica o peptídica deberán relacionarse en el sentido del grupo amino al grupo carboxilo, y de izquierda a derecha. Los grupos amino y carboxilo no deberán representarse en la secuencia.

24. La numeración de las posiciones de aminoácidos deberá comenzar en el primer aminoácido de la secuencia, con el número 1, incluidos los aminoácidos que preceden a la proteína madura, por ejemplo, las presecuencias, las prosecuencias, y las preprosecuencias, así como las secuencias señal. Esa numeración deberá ser continua a lo largo de toda la secuencia en el sentido de amino a carboxilo.

25. Todos los aminoácidos de una secuencia deberán representarse mediante los símbolos descritos en el Anexo I (véase el Cuadro 3 de la Sección 3). Se utilizarán únicamente letras mayúsculas. Todo símbolo utilizado para representar un aminoácido equivale a un único residuo.

26. Si fuese necesario utilizar un símbolo de ambigüedad (que represente dos o más aminoácidos posibles), deberá utilizarse el símbolo más restrictivo. Por ejemplo, si un aminoácido en una posición dada podría ser un ácido aspártico o asparagina, deberá utilizarse el símbolo “B” en vez del símbolo “X”. El símbolo “X” se interpretará como uno de los símbolos “A”, “R”, “N”, “D”, “C”, “Q”, “E”, “G”, “H”, “I”, “L”, “K”, “M”, “F”, “P”, “O”, “S”, “U”, “T”, “W”, “Y”, o “V”, excepto cuando se utilice en una descripción detallada tal como se prevé en los párrafos 28 a 30 o 31 a 33. El símbolo “X” no podrá utilizarse para representar un elemento distinto a un aminoácido. Un único aminoácido podrá representarse mediante el símbolo “X”, junto con una descripción detallada tal como se prevé en los párrafos 28 a 30 o 31 a 33. Para la presentación de las variantes de secuencia, es decir, supresiones, inserciones, o sustituciones, véanse los párrafos 92 a 97.

27. Las secuencias de aminoácidos separadas por uno o más espacios en blanco o símbolos internos de terminación, por ejemplo, “Ter” o asterisco “*” o punto “.”, en una divulgación, deberán presentarse como secuencias distintas en el caso de cada secuencia de aminoácidos que contenga al menos cuatro aminoácidos específicamente definidos y esté contemplada en el párrafo 6. Cada secuencia distinta de este tipo deberá presentarse en la lista de secuencias con su propio identificador de secuencia, utilizando únicamente los símbolos descritos en el Anexo I (véase el Cuadro 3 de la Sección 3). No deberán utilizarse símbolos de terminación ni espacios en las secuencias presentadas en una lista de secuencias.

28. Los aminoácidos modificados, incluidos los D-aminoácidos, deberán representarse en la secuencia como los correspondientes aminoácidos no modificados, cuando sea posible. Todo aminoácido modificado que aparece en una secuencia y que no pueda ser representado por ningún otro símbolo que figure en el Anexo I (véase el Cuadro 3 de la Sección 3), deberá representarse por el símbolo “X”. El símbolo “X” equivale a un único residuo.

29. Los aminoácidos modificados deberán describirse con detalle en el cuadro de características (véanse los párrafos 60 y siguientes). La clave de caracterización “MOD_RES” deberá utilizarse para las modificaciones postraduccionales de los aminoácidos junto con el calificador “NOTE” y la clave de caracterización “SITE” para otros aminoácidos modificados junto con el calificador “NOTE”. El valor del calificador “NOTE” deberá ser ya sea una abreviatura descrita en el Anexo I (véase el Cuadro 4 de la Sección 4), o el nombre completo no abreviado del aminoácido modificado. Las abreviaturas descritas en el Cuadro 4 que se mencionan *supra* o los nombres completos no abreviados no deberán utilizarse en la propia secuencia.

30. Los siguientes ejemplos ilustran la presentación de aminoácidos modificados en la forma prevista en el párrafo 29 *supra*:

Ejemplo 1: Aminoácido modificado (modificación postraduccional)

```
<INSDFeature>
  <INSDFeature_key>MOD_RES</INSDFeature_key>
  <INSDFeature_location>3</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>NOTE</INSDQualifier_name>
      <INSDQualifier_value>3-Hyp</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

Ejemplo 2: Aminoácido modificado (modificación no postraduccional)

```
<INSDFeature>
  <INSDFeature_key>SITE</INSDFeature_key>
  <INSDFeature_location>3</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>NOTE</INSDQualifier_name>
      <INSDQualifier_value>Orn</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

Ejemplo 3: D-aminoácido

```
<INSDFeature>
  <INSDFeature_key>SITE</INSDFeature_key>
  <INSDFeature_location>9</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>NOTE</INSDQualifier_name>
      <INSDQualifier_value>D-Arginine</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

31. Todo aminoácido “desconocido” u “otro” no contemplado en el párrafo 28, deberá representarse mediante el símbolo “X” en la secuencia. El símbolo “X” equivale a un único residuo.

32. Todo aminoácido “desconocido” designado mediante “X” deberá describirse con detalle en el cuadro de características (véanse los párrafos 60 y siguientes.) mediante la clave de caracterización “UNSURE” y facultativamente el calificador “NOTE.” Todo aminoácido “otro” designado como “X” deberá describirse con detalle mediante la clave de caracterización “SITE” o “MOD_RES”, según el caso, y el calificador “NOTE” con el nombre completo no abreviado del aminoácido “otro”.

33. Los siguientes ejemplos ilustran la presentación de aminoácidos “desconocidos” u “otros” en la forma prevista en los párrafos 31 y 32 *supra*:

Ejemplo 1: Aminoácido “desconocido”

```
<INSDFeature>
  <INSDFeature_key>UNSURE</INSDFeature_key>
  <INSDFeature_location>3</INSDFeature_location>
  <INSDFeature_qual>
```

```
<INSDQualifier>
  <INSDQualifier_name>NOTE</INSDQualifier_name>
  <INSDQualifier_value>A or V</INSDQualifier_value>
</INSDQualifier>
</INSDFeature_qual>
</INSDFeature>
```

Ejemplo 2: Aminoácido “otro”

```
<INSDFeature>
  <INSDFeature_key>SITE</INSDFeature_key>
  <INSDFeature_location>3</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>NOTE</INSDQualifier_name>
      <INSDQualifier_value>Homoserine</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

34. Toda región que contiene un número desconocido de residuos “X” contiguos para los cuales se aplica la misma descripción podrá describirse en conjunto utilizando la sintaxis “x..y” como descriptor de localización en el elemento `INSDFeature_location` (véanse los párrafos 65 a 71). Para la presentación de variantes de secuencia, a saber, supresiones, inserciones, o sustituciones, véanse los párrafos 92 a 97.

Presentación de casos especiales

35. Toda secuencia divulgada mediante la enumeración de sus residuos, que se interpreta como una única secuencia contigua a partir de uno o más segmentos no contiguos de una secuencia más grande o de segmentos de diferentes secuencias, deberá figurar en la lista de secuencias como una única secuencia con un único identificador de secuencia.

36. Toda secuencia divulgada mediante la enumeración de sus residuos que contiene regiones de residuos específicamente enumerados separados por una o más regiones de residuos “n” o “X” contiguos (véanse los párrafos 15 y 26, respectivamente), en la que el número exacto de residuos de cada región se divulga, deberá figurar en la lista de secuencias de una única secuencia con un único identificador de secuencia.

37. Toda secuencia divulgada mediante la enumeración de sus residuos que contiene regiones de residuos específicamente enumerados y separados por uno o más huecos compuestos por un número desconocido o no divulgado de residuos deberá figurar en la lista de secuencias como varias secuencias distintas. Cada una de estas secuencias distintas deberá contener una región de residuos específicamente enumerados con su propio identificador de secuencia, en el cual el número de secuencias distintas es igual al número de regiones de residuos específicamente enumerados. Las secuencias que contienen huecos de un número desconocido o no divulgado de residuos no deberán figurar en la lista de secuencias como una única secuencia.

ESTRUCTURA DE LA LISTA DE SECUENCIAS EN FORMATO XML

38. Según lo previsto en el párrafo 5 *supra*, la instancia XML de un archivo que contiene una lista de secuencias compatible con la presente Norma se compone de:

- a) una parte de información general, que contiene la información relativa a la solicitud de patente a la que está asociada la lista de secuencias; y
- b) una parte de datos de secuencia, que contiene uno o más elementos de datos de secuencia, cada uno de los cuales, a su vez contiene información acerca de una secuencia.

En el Anexo III se presenta un ejemplo de una lista de secuencias.

39. La lista de secuencias deberá presentarse en formato XML 1.0 utilizando la DTD presentada en el Anexo II “Definición de tipo de documento para listas de secuencias”.

- a) La primera línea de la instancia XML deberá contener la declaración XML siguiente:

```
<?xml version="1.0" encoding="UTF-8"?>.
```

- b) La segunda línea de la instancia XML deberá contener una declaración de tipo de documento (DOCTYPE):

```
<!DOCTYPE ST26SequenceListing PUBLIC "-//WIPO//DTD Sequence Listing 1.0//EN"
"ST26SequenceListing_V1_0.dtd">.
```

40. La lista de secuencias electrónica completa deberá figurar en un solo archivo. El archivo deberá cifrarse utilizando el lenguaje Unicode UTF-8, con las siguientes restricciones:

- a) la información contenida en los elementos `ApplicantName`, `InventorName` e `InventionTitle` de la parte de información general podrá estar compuesta por cualquier carácter Unicode, excepto los caracteres reservados que deberán sustituirse como se describe en el párrafo 41;
- b) la información contenida en todos los demás elementos de la parte de información general y en todos los elementos de la parte de datos de secuencia
 - o deberá estar compuesta por caracteres imprimibles (incluido el carácter de espacio) de la tabla de códigos de caracteres del alfabeto latino básico de la norma Unicode excepto los caracteres reservados, que deberán sustituirse como se describe en el párrafo 41, (es decir, limitados a los puntos de código Unicode 0020, 0021, 0023 a 0026, 0028 a 003B, 003D, y 003F a 007E – véase el Anexo IV), y
 - o las únicas entidades de caracteres permitidas son las entidades predefinidas descritas en el párrafo 41.

41. En una instancia XML de una lista de secuencias, los siguientes caracteres reservados deberán sustituirse por las entidades predefinidas correspondientes cuando se utilicen en el valor de un atributo o el contenido de un elemento:

Carácter reservado	Entidades predefinidas
<	<
>	>
&	&
"	"
'	'

Véase el párrafo 72 para consultar un ejemplo.

42. Todos los elementos obligatorios deberán indicarse (excepto en el caso definido en el párrafo 58 para las secuencias ignoradas deliberadamente). Los elementos facultativos para los cuales no existe ningún contenido disponible no deberán aparecer en la instancia XML.

Elemento raíz

43. El elemento raíz de una instancia XML según lo dispuesto en esta Norma es el elemento `ST26SequenceListing`, que tiene los siguientes atributos:

Atributo	Descripción	Obligatorio/Facultativo
<code>dtdVersion</code>	Versión de la DTD utilizada para crear este archivo en el formato "V#_#", p. ej. "V1_0".	Obligatorio
<code>fileName</code>	Nombre del archivo que contiene la lista de secuencias.	Facultativo
<code>softwareName</code>	Nombre del programa informático que generó este archivo.	Facultativo
<code>softwareVersion</code>	Versión del programa informático que generó este archivo.	Facultativo
<code>productionDate</code>	Fecha de producción del archivo que contiene la lista de secuencias (programa "AACC-MM-DD").	Facultativo

44. El siguiente ejemplo ilustra el elemento raíz `ST26SequenceListing`, y sus atributos, de una instancia XML en la forma prevista en el párrafo 43 *supra*:

```
<ST26SequenceListing dtdVersion="V1_0" fileName="US11_405455_SEQ1.xml"
softwareName="SEQ1-software-name" softwareVersion="1.0" productionDate="2006-05-10">
  {...}
</ST26SequenceListing>
```

*{...} represents the general information part and the sequence data part that have not been included in this example.

Parte de información general

45. Los elementos de la parte de información general se relacionan a la información relativa a la solicitud de patente, de la siguiente manera:

Elemento	Descripción	Obligatorio/ Facultativo
ApplicationIdentification	La identificación de la solicitud para la cual se presenta la lista de secuencias	Obligatorio cuando una lista de secuencias se suministra en cualquier momento posterior a la asignación del número de solicitud
La ApplicationIdentification se compone de:		
IPOfficeCode	El código ST.3 de la oficina de presentación	Obligatorio
ApplicationNumberText	La identificación de la solicitud suministrada por la oficina de presentación (por ejemplo, PCT/IB2013/099999)	Obligatorio
FilingDate	La fecha de presentación de la solicitud de patente para la cual se presenta la lista de secuencias (formato ST.2 a "AACC-MM-DD", que utiliza 4 dígitos para representar el año civil, 2 dígitos el mes civil y 2 dígitos el número ordinal de un día dentro del mes civil, por ejemplo, 2015-01-31)	Obligatorio cuando una lista de secuencias se suministra en cualquier momento posterior a la asignación de una fecha de presentación
ApplicantFileReference	Un identificador único asignado por el solicitante para identificar una solicitud específica, escrito en los caracteres descritos en el párrafo 40.b)	Obligatorio cuando una lista de secuencias se suministra en cualquier momento anterior a la asignación del número de solicitud; de lo contrario, Facultativo
EarliestPriorityApplicationIdentification	La identificación de la reivindicación de prioridad más antigua (también contiene IPOfficeCode, ApplicationNumberText y FilingDate, véase ApplicationIdentification <i>supra</i>)	Obligatorio cuando se reivindica la prioridad
ApplicantName	El nombre del primer solicitante mencionado escrito en los caracteres descritos en el párrafo 40.a). Este elemento contiene el atributo obligatorio languageCode descrito en el párrafo 47.	Obligatorio

Elemento	Descripción	Obligatorio/ Facultativo
ApplicantNameLatin	Si se escribe ApplicantName en caracteres distintos a los descritos en el párrafo 40.b), también deberá escribirse la traducción o transliteración del nombre del primer solicitante mencionado en los caracteres descritos en el párrafo 40.b)	Obligatorio cuando ApplicantName contiene caracteres no latinos
InventorName	Nombre del primer inventor mencionado escrito en los caracteres descritos en el párrafo 40.a). Este elemento contiene el atributo obligatorio languageCode descrito en el párrafo 47.	Facultativo
InventorNameLatin	Si InventorName se escribe en caracteres distintos a los descritos en el párrafo 40.b), deberá escribirse la traducción o transliteración del inventor mencionado en primer lugar en los caracteres descritos en el párrafo 40.b)	Facultativo
InventionTitle	Título de la invención escrita en los caracteres descritos en el párrafo 40.a) en el idioma de presentación. La traducción del título de la invención en otros idiomas podrá escribirse en los caracteres descritos en el párrafo 40.a) utilizando varios elementos InventionTitle. Este elemento contiene el atributo obligatorio languageCode descrito en el párrafo 48. El título de la invención deberá contener de preferencia dos a siete palabras.	Obligatorio en el idioma de presentación. Facultativo en los otros idiomas.
SequenceTotalQuantity	El número total de todas las secuencias que figuran en la lista de secuencias, incluidas las secuencias ignoradas deliberadamente (o secuencias vacías) (véase el párrafo 9).	Obligatorio

46. Los siguientes ejemplos ilustran la presentación de la parte de información general de la lista de secuencias en la forma prevista en el párrafo 45 *supra*:

Ejemplo 1: Lista de secuencias presentada antes de la asignación de la identificación de la solicitud y la fecha de presentación

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE ST26SequenceListing PUBLIC "-//WIPO//DTD Sequence Listing 1.0//EN"
"ST26SequenceListing_V1_0.dtd">
<ST26SequenceListing dtdVersion="V1_0" fileName="Invention_SEQ1.xml"
softwareName="SEQ1-software-name" softwareVersion="1.0" productionDate="2015-05-10">
  <ApplicantFileReference>AB123</ApplicantFileReference>
  <EarliestPriorityApplicationIdentification>
    <IPOfficeCode>IB</IPOfficeCode>
    <ApplicationNumberText>PCT/IB2013/099999</ApplicationNumberText>
    <FilingDate>2014-07-10</FilingDate>
  </EarliestPriorityApplicationIdentification>
  <ApplicantName languageCode="EN">GENOS Co., Inc.</ApplicantName>
  <InventorName languageCode="EN">Keiko Nakamura</InventorName>
  <InventionTitle languageCode="EN">SIGNAL RECOGNITION PARTICLE RNA AND
PROTEINS</InventionTitle>
```

```
<SequenceTotalQuantity>9</SequenceTotalQuantity>
<SequenceData sequenceIDNumber="1"> {...}* </SequenceData>
<SequenceData sequenceIDNumber="2"> {...} </SequenceData>
<SequenceData sequenceIDNumber="3"> {...} </SequenceData>
<SequenceData sequenceIDNumber="4"> {...} </SequenceData>
<SequenceData sequenceIDNumber="5"> {...} </SequenceData>
<SequenceData sequenceIDNumber="6"> {...} </SequenceData>
<SequenceData sequenceIDNumber="7"> {...} </SequenceData>
<SequenceData sequenceIDNumber="8"> {...} </SequenceData>
<SequenceData sequenceIDNumber="9"> {...} </SequenceData>
</ST26SequenceListing>
```

*{...} representa la información pertinente para cada secuencia que no se ha incluido en este ejemplo.

Ejemplo 2: Lista de secuencias presentada después de la asignación de la identificación de la solicitud y fecha de presentación

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE ST26SequenceListing PUBLIC "-//WIPO//DTD Sequence Listing 1.0//EN"
"ST26SequenceListing_V1_0.dtd">
<ST26SequenceListing dtdVersion="1_0" fileName="Invention_SEQ1.xml"
softwareName="SEQ1-software-name" softwareVersion="1.0" productionDate="2015-05-10">
  <ApplicationIdentification>
    <IPOfficeCode>US</IPOfficeCode>
    <ApplicationNumberText>14/999,999</ApplicationNumberText>
    <FilingDate>2015-01-05</FilingDate>
  </ApplicationIdentification>
  <ApplicantFileReference>AB123</ApplicantFileReference>
  <EarliestPriorityApplicationIdentification>
    <IPOfficeCode>IB</IPOfficeCode>
    <ApplicationNumberText>PCT/IB2014/099999</ApplicationNumberText>
    <FilingDate>2014-07-10</FilingDate>
  </EarliestPriorityApplicationIdentification>
  <ApplicantName languageCode="EN">GENOS Co., Inc.</ApplicantName>
  <InventorName languageCode="EN">Keiko Nakamura</InventorName>
  <InventionTitle languageCode="EN">SIGNAL RECOGNITION PARTICLE RNA AND
PROTEINS</InventionTitle>
  <SequenceTotalQuantity>9</SequenceTotalQuantity>
  <SequenceData sequenceIDNumber="1"> {...}* </SequenceData>
  <SequenceData sequenceIDNumber="2"> {...} </SequenceData>
  <SequenceData sequenceIDNumber="3"> {...} </SequenceData>
  <SequenceData sequenceIDNumber="4"> {...} </SequenceData>
  <SequenceData sequenceIDNumber="5"> {...} </SequenceData>
  <SequenceData sequenceIDNumber="6"> {...} </SequenceData>
  <SequenceData sequenceIDNumber="7"> {...} </SequenceData>
  <SequenceData sequenceIDNumber="8"> {...} </SequenceData>
  <SequenceData sequenceIDNumber="9"> {...} </SequenceData>
</ST26SequenceListing>
```

*{...} representa la información pertinente para cada secuencia que no se ha incluido en este ejemplo.

47. El nombre del solicitante y, facultativamente, el nombre del inventor deberán indicarse en el elemento ApplicantName o InventorName, respectivamente, ya que en general se mencionan en el idioma de presentación de la solicitud. El código de idioma adecuado (véase el párrafo 8.b) deberá indicarse en el atributo languageCode de cada elemento. Cuando el nombre del solicitante indicado contenga caracteres distintos a los del alfabeto latino, como se describe en el párrafo 40.b), también deberá indicarse una transliteración o traducción del nombre del solicitante en caracteres del alfabeto latino en el elemento ApplicantNameLatin. Cuando el nombre del inventor indicado contenga caracteres distintos a los del alfabeto latino, también deberá indicarse una transliteración o traducción del nombre del inventor en caracteres del alfabeto latino en el elemento InventorNameLatin.

48. El título de la invención deberá indicarse en el elemento InventionTitle en el idioma de presentación y también podrá indicarse en otros idiomas utilizando varios elementos InventionTitle (véase el cuadro del párrafo 45). El código de idioma adecuado (véase el párrafo 8.b) deberá indicarse en el atributo languageCode del elemento.

49. El siguiente ejemplo ilustra la presentación de los nombres y el título de la invención en la forma prevista en los párrafos 47 y 48 *supra*:

Ejemplo: El nombre del solicitante y el nombre del inventor se presentan en caracteres japoneses y latinos, y el título de la invención se presenta en japonés, inglés y francés

```
<ApplicantName languageCode="JA">出願製〇株式〇社</ApplicantName>
<ApplicantNameLatin>Shutsugan Pharmaceuticals Kabushiki Kaisha</ApplicantNameLatin>
<InventorName languageCode="JA">特許 太〇</InventorName>
<InventorNameLatin>Taro Tokkyo</InventorNameLatin>
<InventionTitle languageCode="JA"> efg タンパク質のためのマウス abcd-1 遺〇子
</InventionTitle>
<InventionTitle languageCode="EN"> Mus musculus abcd-1 gene for efg protein
</InventionTitle>
<InventionTitle languageCode="FR"> Gène abcd-1 de Mus musculus pour protéine efg
</InventionTitle>
```

Parte de datos de secuencia

50. La parte de datos de secuencia deberá constar de uno o más elementos `SequenceData`, y cada elemento contendrá información sobre una sola secuencia.

51. Cada elemento `SequenceData` deberá tener un atributo obligatorio `sequenceIDNumber`, el cual contiene el identificador de secuencia (véase el párrafo 9) de cada secuencia. Por ejemplo:

```
<SequenceData sequenceIDNumber="1">
```

52. El elemento `SequenceData` deberá contener un elemento dependiente `INSDSeq`, que consiste en otros elementos dependientes de la siguiente manera:

Elemento	Descripción	Obligatorio/No incluido	
		Secuencias	Secuencias ignoradas deliberadamente
<code>INSDSeq_length</code>	Longitud de la secuencia	Obligatorio	Obligatorio, sin ningún valor
<code>INSDSeq_moltype</code>	Tipo de molécula	Obligatorio	Obligatorio, sin ningún valor
<code>INSDSeq_division</code>	Indicación de que una secuencia está asociada a una solicitud de patente	Obligatorio con el valor "PAT"	Obligatorio, sin ningún valor
<code>INSDSeq_feature-table</code>	Lista de anotaciones de la secuencia	Obligatorio	NO debe incluirse
<code>INSDSeq_sequence</code>	Secuencia	Obligatorio	Obligatorio con el valor "000"

53. El elemento `INSDSeq_length` deberá divulgar el número de nucleótidos o aminoácidos de la secuencia contenidos en el elemento `INSDSeq_sequence`. Por ejemplo:

```
<INSDSeq_length>8</INSDSeq_length>
```

54. El elemento `INSDSeq_moltype` deberá divulgar el tipo de molécula que se está presentando. En el caso de las secuencias de nucleótidos, el tipo de molécula deberá indicarse como ADN o ARN. Para las secuencias proteínicas o polipeptídicas, el tipo de molécula deberá indicarse como AA. (Este elemento es distinto de los calificadores "mol_type" y "MOL_TYPE" descritos en los párrafos 55 y 85). Por ejemplo:

```
<INSDSeq_moltype>AA</INSDSeq_moltype>
```

55. Si una secuencia de nucleótidos contiene fragmentos ADN y ARN, el valor de `INSDSeq_moltype` deberá ser "DNA." La molécula combinada ADN/ARN deberá describirse con detalle en el cuadro de características, utilizando la clave de caracterización "source" y el calificador obligatorio "organism" con el valor "synthetic construct" y el calificador obligatorio "mol_type" con el valor "other DNA." Cada fragmento de ADN y ARN de la molécula combinada ADN/ARN deberá describirse con detalle mediante la clave de caracterización "misc_feature" y el calificador "note", lo que indica si el fragmento es un ADN o un ARN.

56. El siguiente ejemplo ilustra la descripción de una secuencia de nucleótidos que contiene fragmentos tanto ADN como ARN, en la forma prevista en el párrafo 55 *supra*:

```
<INSDSeq>
  <INSDSeq_length>120</INSDSeq_length>
  <INSDSeq_moltype>DNA</INSDSeq_moltype>
  <INSDSeq_division>PAT</INSDSeq_division>
  <INSDSeq_feature-table>
    <INSDFeature>
      <INSDFeature_key>source</INSDFeature_key>
      <INSDFeature_location>1..120</INSDFeature_location>
      <INSDFeature_qual>
        <INSDQualifier>
          <INSDQualifier_name>organism</INSDQualifier_name>
          <INSDQualifier_value>synthetic construct</INSDQualifier_value>
        </INSDQualifier>
        <INSDQualifier>
          <INSDQualifier_name>mol_type</INSDQualifier_name>
          <INSDQualifier_value>other DNA</INSDQualifier_value>
        </INSDQualifier>
      </INSDFeature_qual>
    </INSDFeature>
    <INSDFeature>
      <INSDFeature_key>misc_feature</INSDFeature_key>
      <INSDFeature_location>1..60</INSDFeature_location>
      <INSDFeature_qual>
        <INSDQualifier>
          <INSDQualifier_name>note</INSDQualifier_name>
          <INSDQualifier_value>DNA fragment</INSDQualifier_value>
        </INSDQualifier>
      </INSDFeature_qual>
    </INSDFeature>
    <INSDFeature>
      <INSDFeature_key>misc_feature</INSDFeature_key>
      <INSDFeature_location>61..120</INSDFeature_location>
      <INSDFeature_qual>
        <INSDQualifier>
          <INSDQualifier_name>note</INSDQualifier_name>
          <INSDQualifier_value>RNA fragment</INSDQualifier_value>
        </INSDQualifier>
      </INSDFeature_qual>
    </INSDFeature>
  </INSDSeq_feature-table>
  <INSDSeq_sequence>
    cgaccacgcgtccgaggaaccaaccatcacgtttgaggacttcgtgaaggaattggataatacccgctccctacccaaatggcg
    agcgccgactcattgctcctcgtaccgtcgagcggc
  </INSDSeq_sequence>
</INSDSeq>
```

57. El elemento `INSDSeq_sequence` deberá divulgar la secuencia. Los residuos de la secuencia deberán presentarse de forma contigua utilizando únicamente los símbolos adecuados descritos en el Anexo I (véase el Cuadro 1 de la Sección 1 y el Cuadro 3 de la Sección 3). La secuencia no deberá contener números, signos de puntuación o caracteres en blanco.

58. Toda secuencia ignorada deliberadamente deberá presentarse de la siguiente manera:

- a) el elemento `SequenceData` y su atributo `sequenceIDNumber`, indicando como valor el identificador de secuencia de la secuencia ignorada;
- b) los elementos `INSDSeq_length`, `INSDSeq_moltype`, `INSDSeq_division`, presentes pero sin indicar ningún valor;
- c) el elemento `INSDSeq_feature-table` no deberá incluirse; y
- d) el elemento `INSDSeq_sequence`, con el valor "000".

59. El siguiente ejemplo ilustra la presentación de una secuencia ignorada deliberadamente en la forma prevista en el párrafo 58 *supra*:

```
<SequenceData sequenceIDNumber="3">
  <INSDSeq>
    <INSDSeq_length/>
    <INSDSeq_moltype/>
    <INSDSeq_division/>
    <INSDSeq_sequence>000</INSDSeq_sequence>
  </INSDSeq>
</SequenceData>
```

Cuadro de características

60. El cuadro de características contiene información sobre la localización y las funciones de varias regiones de una secuencia específica. Se requiere un cuadro de características para cada secuencia, excepto para toda secuencia ignorada deliberadamente, en cuyo caso no deberá figurar. El cuadro de características figura en el elemento `INSDSeq_feature-table`, que consiste en uno o más elementos `INSDFeature`.

61. Cada elemento `INSDFeature` describe una característica, y consiste en elementos dependientes de la siguiente manera:

Elemento	Descripción	Obligatorio/Facultativo
<code>INSDFeature_key</code>	Palabra o abreviatura que indica una característica	Obligatorio
<code>INSDFeature_location</code>	Región de la secuencia presentada que corresponde a la característica	Obligatorio
<code>INSDFeature_qual</code>	Calificador que contiene información auxiliar acerca de la característica	Obligatorio si la clave de caracterización requiere uno o más calificadores, por ejemplo, <code>source</code> ; de lo contrario, Facultativo

Claves de caracterización

62. El Anexo I contiene la lista completa de claves de caracterización que deberán utilizarse en virtud de esta Norma, junto con la lista completa de los calificadores asociados y una indicación sobre el carácter obligatorio o facultativo de esos calificadores. La Sección 5 del Anexo I presenta la lista completa de las claves de caracterización para las secuencias de nucleótidos y la Sección 7 presenta la lista completa de las claves de caracterización para las secuencias de aminoácidos.

Claves de caracterización obligatorias

63. La clave de caracterización "source" es obligatoria para todas las secuencias de nucleótidos y la clave de caracterización "SOURCE" es obligatoria para todas las secuencias de aminoácidos, excepto para toda secuencia ignorada deliberadamente. Cada secuencia deberá tener una única clave de caracterización "source" o "SOURCE" que abarque toda la secuencia. Si una secuencia proviene de varias fuentes, esas fuentes deberán describirse con detalle en el cuadro de características, utilizando la clave de caracterización "misc_feature" y el calificador "note" para las secuencias de nucleótidos, y la clave de caracterización "REGION" y el calificador "NOTE" para las secuencias de aminoácidos.

64. Algunas claves de caracterización requieren otra clave de caracterización, denominada "Parent Key", que debe utilizarse junto con esas claves de caracterización; por ejemplo, la clave de caracterización "C_region" requiere la clave de caracterización "CDS" (véase la Sección 5 del Anexo I).

Localización de característica

65. El elemento obligatorio `INSDFeature_location` deberá contener al menos un descriptor de localización, que defina un sitio o una región correspondiente a la característica de la secuencia en el elemento `INSDSeq_sequence`, y podrá contener uno o más operador(es) de localización (véanse los párrafos 68 a 71).

66. El descriptor de localización puede ser el número de un único residuo, un sitio entre dos números de residuos adyacentes, una región que delimite una serie de números de residuos contiguos, o un sitio o región que se extienda más allá del residuo, o de la serie de residuos que se ha especificado. Deberán utilizarse varios descriptores de localización junto con un operador de localización cuando la característica corresponda a sitios o regiones de discontinuos de la secuencia (véanse los párrafos 68 a 71). El descriptor de localización no deberá incluir números de residuos fuera de la serie de la secuencia indicada en el elemento `INSDSeq_sequence`.

67. La sintaxis de cada tipo descriptor de localización se indica en el cuadro presentado a continuación, donde *x* e *y* son números de residuos, indicados como enteros no negativos, no superiores a la longitud de la secuencia en el elemento `INSDSeq_sequence`, y *x* es menor que *y*.

Tipo de descriptor de localización	Sintaxis	Descripción
Número único de residuo	x	Designa un único residuo en la secuencia presentada.
Números de residuos que limitan un tramo de secuencia	$x..y$	Designa una serie continua de residuos delimitada por un residuo de inicio y uno de fin, incluidos éstos.
Residuos antes del primero, o después del último, residuo especificado	$<x$ $>x$ $<x..y$ $x..>y$	Designa una región que incluye un residuo o una serie de residuos especificada y que se extiende más allá del residuo especificado. Los símbolos '<' y '>' podrán utilizarse con un único residuo, o los números de los residuos de inicio y de fin de una serie de residuos para indicar que las características se extienden más allá del número de residuo especificado.
Un sitio entre dos números de residuo adyacentes	x^y	Designa un sitio entre dos residuos adyacentes, por ejemplo, el sitio de una unión endonucleolítica. Los números de posición de los residuos adyacentes están separados por el símbolo (^). Los formatos permitidos para este descriptor son x^{x+1} (por ejemplo 55^{56}), o para nucleótidos circulares, x^1 , donde "x" es la longitud total de la molécula, es decir, 1000^1 para una molécula circular con una longitud 1000.

68. Un operador de localización es un prefijo de un descriptor de localización o de una combinación de descriptores de localización que corresponden a una característica única pero discontinua, y especifica el lugar correspondiente a la característica en la secuencia indicada, y la manera de interpretar la característica. A continuación se suministra una lista de operadores de localización con sus respectivas definiciones.

a) Operador de localización para nucleótidos y aminoácidos:

Sintaxis de localización	Descripción
<code>join(location,location, ... location)</code>	Las localizaciones indicadas están unidas (colocadas extremo con extremo) para formar una secuencia contigua.
<code>order(location,location, ... location)</code>	Los elementos se encuentran en el orden especificado pero ninguna información permite determinar si la unión de esos elementos es razonable.

b) Operador de localización únicamente para nucleótidos:

Sintaxis de localización	Descripción
<code>complement(location)</code>	Indica que la característica está localizada en la cadena complementaria al tramo de la secuencia especificado por el descriptor de localización, cuando se lee en el sentido de 5' a 3'.

69. Los operadores de localización de unión (join) u orden (order) requieren al menos dos descriptores de localización separados por una coma. Los descriptores de localización relativos a sitios situados entre dos residuos adyacentes, es decir x^y , no podrán utilizarse en una localización de unión u orden. La utilización del operador de localización join implica que los residuos designados por los descriptores de localización están puestos en contacto físicamente mediante procesos biológicos (por ejemplo, los exones que contribuyen a una característica de una región de codificación).

70. El operador de localización "complement" puede utilizarse únicamente para los nucleótidos. El operador "Complement" puede utilizarse en combinación ya sea con los operadores "join" u "order" dentro de la misma localización. No deberán utilizarse combinaciones de los operadores "join" y "order" en la misma localización.

71. Los siguientes ejemplos ilustran localizaciones de características en la forma prevista en los párrafos 65 a 70 *supra*:

a) localizaciones para los nucleótidos y aminoácidos:

Ejemplo de localización	Descripción
467	Designa el residuo 467 de la secuencia.
123^124	Designa un sitio entre los residuos 123 y 124.

Ejemplo de localización	Descripción
340..565	Designa una serie continua de residuos delimitada por los residuos 340 y 565, incluidos éstos.
<1	Designa una localización de característica antes del primer residuo.
<345..500	Indica que se desconoce el punto exacto del límite inferior de una característica. La localización comienza en algún residuo anterior al 345 y continúa hasta el residuo 500, incluido éste.
<1..888	Indica que la característica comienza antes del primer residuo de la secuencia y continúa hasta el residuo 888, incluido éste.
1..>888	Indica que la característica comienza en el primer residuo de la secuencia y continúa más allá del residuo 888.
join(12..78,134..202)	Indica que las regiones 12 a 78 y 134 a 202 deben unirse para formar una secuencia contigua.

b) localizaciones únicamente para nucleótidos:

Ejemplo de localización	Descripción
complement(34..126)	Comienza en la base complementaria a 126 y termina en la base complementaria a la base 34 (la característica está en la cadena complementaria a la cadena presentada).
complement(join(2691..4571, 4918..5163))	Une las bases de 2691 a 4571 y 4918 a 5163, y luego complementa los segmentos unidos (la característica está en la cadena complementaria a la cadena presentada).
join(complement(4918..5163), complement(2691..4571))	Complementa las regiones 4918 a 5163 y 2691 a 4571, luego une los segmentos complementados (la característica está en la cadena complementaria a la cadena presentada).

72. En una instancia XML de una lista de secuencias, los caracteres "<" y ">" de un descriptor de localización deberán sustituirse por las entidades predefinidas adecuadas (véase el párrafo 41). Por ejemplo:

```
Feature location "<1":
<INSDFeature_location>&lt;1</INSDFeature_location>

Feature location "1..>888":
<INSDFeature_location>1..&gt;888</INSDFeature_location>
```

Calificadores de caracterización

73. Los calificadores se utilizan para suministrar información acerca de las características que complementa la información indicada por la clave de caracterización y la localización de característica. Existen tres tipos de formatos de valor para representar los diferentes tipos de información comunicada por los calificadores, a saber:

- a) texto libre (véanse los párrafos 86 y 87);
- b) vocabulario controlado o valores enumerados (por ejemplo, un número o fecha); y
- c) secuencias.

74. La Sección 6 del Anexo I contiene una lista completa de calificadores y sus formatos de valor especificados, dado el caso, para cada clave de caracterización de nucleótidos, y la Sección 8 contiene la lista completa de calificadores para cada clave de caracterización de aminoácidos.

75. Toda secuencia contemplada en el párrafo 6 que se indique como valor calificador deberá presentarse de manera clara en la lista de secuencias con su propio identificador de secuencia.

Calificadores de caracterización obligatorios

76. Una clave caracterización obligatoria, es decir, “source” para las secuencias de nucleótidos y “SOURCE” para las secuencias de aminoácidos, deberá incluir dos calificadores obligatorios, “organism” y “mol_type” para las secuencias de nucleótidos y “ORGANISM” y “MOL_TYPE” para las secuencias de aminoácidos. Algunas claves de caracterización facultativas también necesitan calificadores obligatorios.

Elementos de los calificadores

77. El elemento `INSDFeature_qual` contiene uno o más elementos `INSDQualifier`. Cada elemento `INSDQualifier` representa un calificador único y consiste en dos elementos dependientes de la siguiente manera:

Elemento	Descripción	Obligatorio/Facultativo
<code>INSDQualifier_name</code>	Nombre del calificador (véanse las Secciones 6 y 8 del Anexo I)	Obligatorio
<code>INSDQualifier_value</code>	Valor del calificador, dado el caso, en el formato especificado (véanse las Secciones 6 y 8 del Anexo I)	Obligatorio, cuando se especifica (véanse las Secciones 6 y 8 del Anexo I)

78. El calificador de organismo, es decir “organism” para las secuencias de nucleótidos (véase la Sección 6 del Anexo I) y “ORGANISM” para las secuencias de aminoácidos (véase la Sección 8 del Anexo I) deberá divulgar la fuente, es decir, un organismo único u origen de la secuencia que se presenta. Las designaciones de los organismos deberán seleccionarse a partir de una base de datos taxonómica.

79. Si la secuencia existe en estado natural y el organismo fuente tiene una designación de género y especie en latín, esa designación deberá utilizarse como valor calificador. El nombre más usual en inglés podrá especificarse utilizando el calificador “note” para las secuencias de nucleótidos y el calificador “NOTE” para las secuencias de aminoácidos, pero no deberá utilizarse en el valor calificador del organismo.

80. Los siguientes ejemplos ilustran la fuente de las secuencias presentadas en la forma prevista en los párrafos 78 y 79 *supra*:

Ejemplo 1: Fuente de una secuencia de nucleótidos

```
<INSDSeq_feature-table>
  <INSDFeature>
    <INSDFeature_key>source</INSDFeature_key>
    <INSDFeature_location>1..5164</INSDFeature_location>
    <INSDFeature_qual>
      <INSDQualifier>
        <INSDQualifier_name>organism</INSDQualifier_name>
        <INSDQualifier_value>Solanum lycopersicum</INSDQualifier_value>
      </INSDQualifier>
      <INSDQualifier>
        <INSDQualifier_name>note</INSDQualifier_name>
        <INSDQualifier_value>common name: tomato</INSDQualifier_value>
      </INSDQualifier>
      <INSDQualifier>
        <INSDQualifier_name>mol_type</INSDQualifier_name>
        <INSDQualifier_value>genomic DNA</INSDQualifier_value>
      </INSDQualifier>
    </INSDFeature_qual>
  </INSDFeature>
</INSDSeq_feature-table>
```

Ejemplo 2: Fuente de una secuencia proteínica

```
<INSDSeq_feature-table>
  <INSDFeature>
    <INSDFeature_key>SOURCE</INSDFeature_key>
    <INSDFeature_location>1..174</INSDFeature_location>
    <INSDFeature_qual>
      <INSDQualifier>
        <INSDQualifier_name>ORGANISM</INSDQualifier_name>
        <INSDQualifier_value>Homo sapiens</INSDQualifier_value>
      </INSDQualifier>
    </INSDFeature_qual>
  </INSDFeature>
</INSDSeq_feature-table>
```

```

        <INSDQualifier_name>MOL_TYPE</INSDQualifier_name>
        <INSDQualifier_value>protein</INSDQualifier_value>
    </INSDQualifier>
</INSDFeature_qual>
</INSDFeature>
</INSDSeq_feature-table>

```

81. Si la secuencia existe en estado natural y existe el nombre en latín del género del organismo fuente, pero la especie no se ha especificado o identificado, el valor calificador del organismo deberá indicar el género en latín seguido por "sp.". Por ejemplo:

```

<INSDQualifier_name>organism</INSDQualifier_name>
<INSDQualifier_value>Bacillus sp.</INSDQualifier_value>

```

82. Si la fuente de la secuencia es natural, pero se desconoce la designación en latín del género y la especie del organismo, se deberá indicar "unidentified" como valor calificador del organismo, seguido por toda información taxonómica conocida en el calificador "note" para las secuencias de nucleótidos y en el calificador "NOTE" para las secuencias de aminoácidos. Por ejemplo:

```

<INSDQualifier_name>organism</INSDQualifier_name>
<INSDQualifier_value>unidentified</INSDQualifier_value>
<INSDQualifier_name>note</INSDQualifier_name>
<INSDQualifier_value>bacterium B8</INSDQualifier_value>

```

83. Si la secuencia existe en estado natural y el organismo fuente no tiene una designación en latín de género y especie, tal como un virus, entonces deberá utilizarse cualquier otro nombre científico aceptable (por ejemplo, "Canine adenovirus tipo 2") como valor calificador del organismo. Por ejemplo:

```

<INSDQualifier_name>organism</INSDQualifier_name>
<INSDQualifier_value>Canine adenovirus type 2</INSDQualifier_value>

```

84. Si la secuencia no existe en estado natural, deberá indicarse "synthetic construct" como valor calificador del organismo. Se podrá especificar información adicional sobre la manera en que se generó la secuencia utilizando el calificador "note" para las secuencias de nucleótidos y el calificador "NOTE" para las secuencias de aminoácidos. Por ejemplo:

```

<INSDSeq_feature-table>
  <INSDFeature>
    <INSDFeature_key>SOURCE</INSDFeature_key>
    <INSDFeature_location>1..40</INSDFeature_location>
    <INSDFeature_qual>
      <INSDQualifier>
        <INSDQualifier_name>ORGANISM</INSDQualifier_name>
        <INSDQualifier_value>synthetic construct</INSDQualifier_value>
      </INSDQualifier>
      <INSDQualifier>
        <INSDQualifier_name>MOL_TYPE</INSDQualifier_name>
        <INSDQualifier_value>protein</INSDQualifier_value>
      </INSDQualifier>
      <INSDQualifier>
        <INSDQualifier_name>NOTE</INSDQualifier_name>
        <INSDQualifier_value>synthetic peptide used as assay for
antibodies</INSDQualifier_value>
      </INSDQualifier>
    </INSDFeature_qual>
  </INSDFeature>
</INSDSeq_feature-table>

```

85. El calificador "mol_type" para las secuencias de nucleótidos (véase la Sección 6 del Anexo I) y "MOL_TYPE" para las secuencias de aminoácidos (véase la Sección 8 del Anexo I) deberá divulgar el tipo de molécula representado en la secuencia. Estos calificadores son distintos del elemento INSDSeq_moltype descrito en el párrafo 54:

a) Para una secuencia de nucleótidos, el valor calificador de "mol_type" deberá ser uno de los siguientes: "genomic DNA", "genomic RNA", "mRNA", "tRNA", "rRNA", "other RNA", "other DNA", "transcribed RNA", "viral cRNA", "unassigned DNA", o "unassigned RNA". Si la secuencia no existe en estado natural, es decir si el valor del calificador "organism" es "synthetic construct", el valor calificador de "mol_type" deberá ser "other RNA" o "other DNA";

- b) Para las secuencias de aminoácidos, el valor calificador de "MOL_TYPE" es "protein".

Texto libre

86. El texto libre es un tipo de formato de valor para ciertos calificadores (como se describe en el Anexo I), que se presenta en forma de una frase de texto descriptiva preferentemente en inglés.

87. La utilización del texto libre deberá limitarse a unos cuantos términos cortos indispensables para entender una característica de la secuencia. Para cada calificador, el texto libre no deberá ser superior a 1000 caracteres.

Secuencias codificadoras

88. La clave de caracterización "CDS" podrá utilizarse para identificar secuencias codificadoras, es decir secuencias de nucleótidos que corresponden a la secuencia de aminoácidos en una proteína y el codón de terminación. El INSDFeature_location deberá identificar la localización de la característica "CDS" y debe incluir el codón de terminación.

89. Los calificadores "transl_table" y "translation" podrán utilizarse con la clave de caracterización "CDS" (véase el Anexo I). Cuando el calificador "transl_table" no se utiliza, se asume la utilización de la tabla de códigos normalizados (véase el Cuadro 5 de la Sección 9 del Anexo I).

90. Toda secuencia proteínica codificada por la secuencia codificadora y divulgada en un calificador "translation" contemplado en el párrafo 6 deberá tener su propio identificador de secuencia, y presentarse en la lista de secuencias. El identificador de secuencia asignado a la secuencia proteínica deberá figurar como valor del calificador "protein_id" con la clave caracterización "CDS". El calificador "ORGANISM" de la clave de caracterización "SOURCE" para la secuencia proteínica deberá ser idéntico al de su secuencia codificadora. Por ejemplo:

```
<INSDSeq_feature-table>
  <INSDFeature>
    <INSDFeature_key>CDS</INSDFeature_key>
    <INSDFeature_location>1..507</INSDFeature_location>
    <INSDFeature_qualifiers>
      <INSDQualifier>
        <INSDQualifier_name>transl_table</INSDQualifier_name>
        <INSDQualifier_value>1</INSDQualifier_value>
      </INSDQualifier>
      <INSDQualifier>
        <INSDQualifier_name>translation</INSDQualifier_name>
        <INSDQualifier_value>
          MLVHLERTTIMDFDFSSLINLPLIWGLLIAIAVLLYILMDGFDLGIGILLPFAPSDKCRDHMISSIAPFWDGNETWLVLGGGGLFAA
          FPLAYSILMPAFYIPIIIMLLGLIVRGVSFEFRFKAEGKYRRLWDYAFHFGSLGAAPCQGMILGAFIHGVEVNGRNFSGGQLM
        </INSDQualifier_value>
      </INSDQualifier>
      <INSDQualifier>
        <INSDQualifier_name>protein_id</INSDQualifier_name>
        <INSDQualifier_value>89</INSDQualifier_value>
      </INSDQualifier>
    </INSDFeature_qualifiers>
  </INSDFeature>
</INSDSeq_feature-table>
```

Variantes

91. Toda secuencia principal y toda variante de esa secuencia, cada una de ellas divulgada mediante la enumeración de sus residuos y contemplada en el párrafo 6, deberá presentarse en la lista de secuencias con su propio identificador de secuencia.

92. Toda variante de secuencia, divulgada únicamente por referencia a una o varias supresiones, inserciones o sustituciones en una secuencia principal en la lista de secuencias, podrá presentarse en la lista de secuencias. Cuando se indica en la lista de secuencias, tal variante de secuencia:

- podrá presentarse por anotación de la secuencia principal, si contiene una o varias variaciones en una única localización o en varias localizaciones distintas y esas variaciones aparecen de forma independiente;
- deberá presentarse como una secuencia distinta con su propio identificador de secuencia, si contiene variaciones en varias localizaciones distintas y esas variaciones aparecen de forma interdependiente; y
- debe presentarse como una secuencia distinta con su propio identificador de secuencia, si contiene una secuencia que ha sido insertada o sustituida que contiene más de 1000 residuos (véase el párrafo 87).

93. El cuadro presentado a continuación indica la utilización adecuada de las claves y calificadores de caracterización para las variantes de ácidos nucleicos y aminoácidos:

Tipo de secuencia	Clave de caracterización	Calificador	Utilización
Ácido nucleico	variation	replace	Mutaciones y polimorfismos que existen en estado natural, por ejemplo, los alelos o los polimorfismos de longitud de los fragmentos de restricción.
Ácido nucleico	misc_difference	replace	Variabilidad introducida artificialmente, por ejemplo, mediante manipulación genética o síntesis química.
Aminoácido	VAR_SEQ	NOTE	Variante producida por empalme diferencial, utilización de promotor alternativo, iniciación alternativa y o desplazamiento del marco ribosomal.
Aminoácido	VARIANT	NOTE	Todo tipo de variante para el cual VAR_SEQ no es aplicable.

94. La anotación de una secuencia principal para una variante específica deberá contener una clave de caracterización y un calificador, como se indica en el cuadro *supra*, y la localización de la característica. Toda supresión deberá representarse mediante un valor calificador vacío. Todo residuo insertado o sustituido deberá indicarse en el calificador “replace” o “NOTE”. El valor de los calificadores “replace” y “NOTE” es un texto libre que no deberá ser superior a 1000 caracteres, tal como se prevé en el párrafo 87. Para las secuencias contempladas en el párrafo 6 que se presenten como inserción o sustitución en un valor calificador, véase el párrafo 97. El valor calificador puede contener una lista de los residuos alternativos que pueden insertarse o sustituirse.

95. Los símbolos descritos en el Anexo I (véanse los Cuadros 1 a 4 de las Secciones 1 a 4, respectivamente) deberán utilizarse para representar las variantes de residuos, dado el caso. Cuando la variante de residuo es un residuo modificado que no se describe en los Cuadros 2 o 4 del Anexo I, deberá indicarse el nombre completo no abreviado del residuo modificado como valor calificador.

96. Los siguientes ejemplos ilustran la presentación de variantes en la forma prevista en los párrafos 92 a 95 *supra*:

Ejemplo 1: Clave de caracterización “variation” para una sustitución en una secuencia de nucleótidos.
Una citosina sustituye al nucleótido definido en la posición 413 de la secuencia.

```
<INSDFeature>
  <INSDFeature_key>variation</INSDFeature_key>
  <INSDFeature_location>413</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>replace</INSDQualifier_name>
      <INSDQualifier_value>c</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

Ejemplo 2: Clave de caracterización “misc_difference” para una supresión en una secuencia de nucleótidos.
Se ha suprimido el nucleótido en la posición 413.

```
<INSDFeature>
  <INSDFeature_key>misc_difference</INSDFeature_key>
  <INSDFeature_location>413</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>replace</INSDQualifier_name>
      <INSDQualifier_value></INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

Ejemplo 3: Clave de caracterización “misc_difference” para una inserción en una secuencia de nucleótidos.
La secuencia “atgccaaatat” se ha insertado entre las posiciones 100 y 101 de la secuencia principal.

```
<INSDFeature>
  <INSDFeature_key>misc_difference</INSDFeature_key>
```

```
<INSDFeature_location>100^101</INSDFeature_location>
<INSDFeature_qual>
  <INSDQualifier>
    <INSDQualifier_name>replace</INSDQualifier_name>
    <INSDQualifier_value>atgccaaatat</INSDQualifier_value>
  </INSDQualifier>
</INSDFeature_qual>
</INSDFeature>
```

Ejemplo 4: Clave de caracterización “VARIANT” para una sustitución en una secuencia de aminoácidos - El aminoácido definido en la posición 100 de la secuencia puede sustituirse por I, A, F, Y, alle, MeIle, o Nle.

```
<INSDFeature>
  <INSDFeature_key>VARIANT</INSDFeature_key>
  <INSDFeature_location>100</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>NOTE</INSDQualifier_name>
      <INSDQualifier_value>I, A, F, Y, aIle, MeIle, or Nle
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

Ejemplo 5: Clave de caracterización “VARIANT” para una sustitución en una secuencia de aminoácidos: El aminoácido definido en la posición 100 de la secuencia puede sustituirse por cualquier aminoácido excepto por Lys, Arg or His.

```
<INSDFeature>
  <INSDFeature_key>VARIANT</INSDFeature_key>
  <INSDFeature_location>100</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>NOTE</INSDQualifier_name>
      <INSDQualifier_value>not K, R, or H</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
```

97. Toda secuencia contemplada en el párrafo 6 que se indique como una inserción o sustitución en un valor calificador para una anotación de secuencia principal también deberá presentarse en la lista de secuencias con su propio identificador de secuencia.

[Sigue el Anexo I a la ST.26]

ST.26 - ANNEX I

CONTROLLED VOCABULARY

Final Draft

Proposal presented by the SEQL Task Force for consideration and adoption at the CWS/4

TABLE OF CONTENTS

SECTION 1: LIST OF NUCLEOTIDES	23
SECTION 2: LIST OF MODIFIED NUCLEOTIDES	23
SECTION 3: LIST OF AMINO ACIDS	25
SECTION 4: LIST OF MODIFIED AND UNUSUAL AMINO ACIDS	26
SECTION 5: FEATURES KEYS FOR NUCLEIC SEQUENCES	27
SECTION 6: DESCRIPTION OF QUALIFIERS FOR NUCLEIC SEQUENCES	47
SECTION 7: FEATURE KEYS FOR AMINO ACID SEQUENCES	65
SECTION 8: QUALIFIERS FOR AMINO ACID SEQUENCES	71
SECTION 9: GENETIC CODES TABLES	72

SECTION 1: LIST OF NUCLEOTIDES

The nucleotide base codes to be used in sequence listings are presented in Table 1. The symbol "t" will be construed as thymine in DNA and uracil in RNA when it is used with no further description. Where an ambiguity symbol (representing two or more bases in the alternative) is appropriate, the most restrictive symbol should be used. For example, if a base in a given position could be "a or g," then "r" should be used, rather than "n". The symbol "n" will be construed as "a or c or g or t/u" when it is used with no further description.

Table 1: List of nucleotides

Symbol	Nucleotide
a	adenine
c	cytosine
g	guanine
t	thymine in DNA/uracil in RNA (t/u)
m	a or c
r	a or g
w	a or t/u
s	c or g
y	c or t/u
k	g or t/u
v	a or c or g; not t/u
h	a or c or t/u; not g
d	a or g or t/u; not c
b	c or g or t/u; not a
n	a or c or g or t/u; unknown or other

SECTION 2: LIST OF MODIFIED NUCLEOTIDES

The abbreviations listed in Table 2 are the only permitted values for the mod_base qualifier. Where a specific modified nucleotide is not present in the table below, then the abbreviation "OTHER" must be used as its value. If the abbreviation is "OTHER," then the complete unabbreviated name of the modified base must be provided in a note qualifier. The abbreviations provided in Table 2 must not be used in the sequence itself.

Table 2: List of modified nucleotides

Abbreviation	Modified Nucleotide
ac4c	4-acetylcytidine
chm5u	5-(carboxyhydroxymethyl)uridine
cm	2'-O-methylcytidine
cmnm5s2u	5-carboxymethylaminomethyl-2-thiouridine
cmnm5u	5-carboxymethylaminomethyluridine
d	dihydrouridine
fm	2'-O-methylpseudouridine
gal q	beta,D-galactosylqueosine
gm	2'-O-methylguanosine
i	inosine
i6a	N6-isopentenyladenosine
m1a	1-methyladenosine
m1f	1-methylpseudouridine
m1g	1-methylguanosine
m1i	1-methylinosine
m22g	2,2-dimethylguanosine
m2a	2-methyladenosine
m2g	2-methylguanosine
m3c	3-methylcytidine
m5c	5-methylcytidine
m6a	N6-methyladenosine
m7g	7-methylguanosine
mam5u	5-methylaminomethyluridine
mam5s2u	5-methoxyaminomethyl-2-thiouridine

Abbreviation	Modified Nucleotide
man q	beta,D-mannosylqueosine
mcm5s2u	5-methoxycarbonylmethyl-2-thiouridine
mcm5u	5-methoxycarbonylmethyluridine
mo5u	5-methoxyuridine
ms2i6a	2-methylthio-N6-isopentenyladenosine
ms2t6a	N-((9-beta-D-ribofuranosyl-2-methyltiopurine-6-yl)carbamoyl)threonine
mt6a	N-((9-beta-D-ribofuranosylpurine-6-yl)N-methyl-carbamoyl)threonine
mv	uridine-5-oxyacetic acid-methylester
o5u	uridine-5-oxyacetic acid (v)
osyw	wybutoxosine
p	pseudouridine
q	queosine
s2c	2-thiocytidine
s2t	5-methyl-2-thiouridine
s2u	2-thiouridine
s4u	4-thiouridine
t6a	N-((9-beta-D-ribofuranosylpurine-6-yl)carbamoyl)threonine
tm	2'-O-methyl-5-methyluridine
um	2'-O-methyluridine
yw	wybutosine
x	3-(3-amino-3-carboxypropyl)uridine, (acp3)u
OTHER	(requires note qualifier)

SECTION 3: LIST OF AMINO ACIDS

The amino acid codes to be used in sequence are presented in Table 3. Where an ambiguity symbol (representing two or more amino acids in the alternative) is appropriate, the most restrictive symbol should be used. For example, if an amino acid in a given position could be aspartic acid or asparagine, the symbol "B" should be used, rather than "X". The symbol "X" will be construed as any one of "A", "R", "N", "D", "C", "Q", "E", "G", "H", "I", "L", "K", "M", "F", "P", "O", "S", "U", "T", "W", "Y", or "V", when it is used with no further description.

Table 3: List of amino acids

Symbol	Amino acid
A	Alanine
R	Arginine
N	Asparagine
D	Aspartic acid (Aspartate)
C	Cysteine
Q	Glutamine
E	Glutamic acid (Glutamate)
G	Glycine
H	Histidine
I	Isoleucine
L	Leucine
K	Lysine
M	Methionine
F	Phenylalanine
P	Proline
O	Pyrrolysine
S	Serine
U	Selenocysteine
T	Threonine
W	Tryptophan
Y	Tyrosine
V	Valine
B	Aspartic acid or Asparagine
Z	Glutamine or Glutamic acid
J	Leucine or Isoleucine
X	unknown or other

SECTION 4: LIST OF MODIFIED AND UNUSUAL AMINO ACIDS

Table 4 lists the only permitted abbreviations for a modified or unusual amino acid in the mandatory qualifier “NOTE” for feature keys “MOD_RES” or “SITE”. The value for the qualifier “NOTE” must be either an abbreviation from this table, where appropriate, or the complete, unabbreviated name of the modified amino acid. The abbreviations (or full names) provided in this table must not be used in the sequence itself.

Table 4: List of modified and unusual amino acids

Abbreviation	Modified or Unusual Amino acid
Aad	2-Aminoadipic acid
bAad	3-Aminoadipic acid
bAla	beta-Alanine, beta-Aminopropionic acid
Abu	2-Aminobutyric acid
4Abu	4-Aminobutyric acid, piperidinic acid
Acp	6-Aminocaproic acid
Ahe	2-Aminoheptanoic acid
Aib	2-Aminoisobutyric acid
bAib	3-Aminoisobutyric acid
Apm	2-Aminopimelic acid
Dbu	2,4-Diaminobutyric acid
Des	Desmosine
Dpm	2,2'-Diaminopimelic acid
Dpr	2,3-Diaminopropionic acid
EtGly	N-Ethylglycine
EtAsn	N-Ethylasparagine
Hyl	Hydroxylysine
aHyl	allo-Hydroxylysine
3Hyp	3-Hydroxyproline
4Hyp	4-Hydroxyproline
Ide	Isodesmosine
alle	allo-Isoleucine
MeGly	N-Methylglycine, sarcosine
Melle	N-Methylisoleucine
MeLys	6-N-Methyllysine
MeVal	N-Methylvaline
Nva	Norvaline
Nle	Norleucine
Orn	Ornithine

SECTION 5: FEATURES KEYS FOR NUCLEIC SEQUENCES

This paragraph contains the list of allowed feature keys to be used for nucleotide sequences, and lists mandatory and optional qualifiers. The feature keys are listed in alphabetic order. The feature keys can be used for either DNA or RNA unless otherwise indicated under "Molecule scope". Some feature keys include a 'Parent Key' designation; when a parent key is indicated in the description of a feature key, it is mandatory that the designated parent key be used. Certain Feature Keys may be appropriate for use with artificial sequences in addition to the specified "organism scope".

Feature key names must be used in the XML instance of the sequence listing exactly as they appear following "Feature key" in the descriptions below, except for the feature keys 3'UTR and 5'UTR. See "Comment" in the description for the 3'UTR and 5'UTR feature keys.

5.1.	Feature Key	attenuator
	Definition	1) region of DNA at which regulation of termination of transcription occurs, which controls the expression of some bacterial operons; 2) sequence segment located between the promoter and the first structural gene that causes partial termination of transcription
	Optional qualifiers	allele gene gene_synonym map note operon phenotype
	Organism scope	prokaryotes
	Molecule scope	DNA

5.2.	Feature Key	C_region
	Definition	constant region of immunoglobulin light and heavy chains, and T-cell receptor alpha, beta, and gamma chains; includes one or more exons depending on the particular chain
	Optional qualifiers	allele gene gene_synonym map note product pseudo pseudogene standard_name
	Parent Key	CDS
	Organism scope	eukaryotes

5.3.	Feature Key	CAAT_signal
	Definition	CAAT box; part of a conserved sequence located about 75 bp up-stream of the start point of eukaryotic transcription units which may be involved in RNA polymerase binding; consensus=GG(C or T)CAATCT [1, 2]
	Optional qualifiers	allele gene gene_synonym map note
	Organism scope	eukaryotes and eukaryotic viruses
	Molecule scope	DNA
	References	[1] Efstratiadis, A. et al. Cell 21, 653-668 (1980) [2] Nevins, J.R. "The pathway of eukaryotic mRNA formation" Ann Rev Biochem 52, 441-466 (1983)
5.4.	Feature Key	CDS
	Definition	coding sequence; sequence of nucleotides that corresponds with the sequence of amino acids in a protein (location includes stop codon); feature may include amino acid conceptual translation
	Optional qualifiers	allele artificial_location codon_start EC_number exception function gene gene_synonym map note number operon product protein_id pseudo pseudogene ribosomal_slippage standard_name translation transl_except transl_table trans_splicing
	Comment	codon_start qualifier has valid value of 1 or 2 or 3, indicating the offset at which the first complete codon of a coding feature can be found, relative to the first base of that feature; transl_table defines the genetic code table used if other than the Standard or universal genetic code table; genetic code exceptions outside the range of the specified tables are reported in transl_except qualifier; only one of the qualifiers translation and pseudo are permitted with a CDS feature key; when the translation qualifier is used, the protein_id qualifier is mandatory if the translation product contains four or more amino acids

5.5.	Feature Key	centromere
	Definition	region of biological interest identified as a centromere and which has been experimentally characterized
	Optional qualifiers	note standard_name
	Comment	the centromere feature describes the interval of DNA that corresponds to a region where chromatids are held and a kinetochore is formed
5.6.	Feature Key	D-loop
	Definition	displacement loop; a region within mitochondrial DNA in which a short stretch of RNA is paired with one strand of DNA, displacing the original partner DNA strand in this region; also used to describe the displacement of a region of one strand of duplex DNA by a single stranded invader in the reaction catalyzed by RecA protein
	Optional qualifiers	allele gene gene_synonym map note
	Molecule scope	DNA
5.7.	Feature Key	D_segment
	Definition	Diversity segment of immunoglobulin heavy chain, and T-cell receptor beta chain
	Optional qualifiers	allele gene gene_synonym map note product pseudo pseudogene standard_name
	Parent Key	CDS
	Organism scope	eukaryotes
5.8.	Feature Key	enhancer
	Definition	a cis-acting sequence that increases the utilization of (some) eukaryotic promoters, and can function in either orientation and in any location (upstream or downstream) relative to the promoter
	Optional qualifiers	allele bound_moiety gene gene_synonym map note standard_name
	Organism scope	eukaryotes and eukaryotic viruses

5.9.	Feature Key	exon
	Definition	region of genome that codes for portion of spliced mRNA, rRNA and tRNA; may contain 5' UTR, all CDSs and 3' UTR
	Optional qualifiers	allele EC_number function gene gene_synonym map note number product pseudo pseudogene standard_name trans_splicing
5.10.	Feature Key	GC_signal
	Definition	GC box; a conserved GC-rich region located upstream of the start point of eukaryotic transcription units which may occur in multiple copies or in either orientation; consensus=GGGCGG
	Optional qualifiers	allele gene gene_synonym map note
	Organism scope	eukaryotes and eukaryotic viruses
5.11.	Feature Key	gene
	Definition	region of biological interest identified as a gene and for which a name has been assigned
	Optional qualifiers	allele function gene gene_synonym map note operon product pseudo pseudogene phenotype standard_name trans_splicing
	Comment	the gene feature describes the interval of DNA that corresponds to a genetic trait or phenotype; the feature is, by definition, not strictly bound to its positions at the ends; it is meant to represent a region where the gene is located.

5.12.	Feature Key	i DNA
	Definition	intervening DNA; DNA which is eliminated through any of several kinds of recombination
	Optional qualifiers	allele function gene gene_synonym map note number standard_name
	Molecule scope	DNA
	Comment	e.g., in the somatic processing of immunoglobulin genes.
5.13.	Feature Key	intron
	Definition	a segment of DNA that is transcribed, but removed from within the transcript by splicing together the sequences (exons) on either side of it
	Optional qualifiers	allele function gene gene_synonym map note number pseudo pseudogene standard_name trans_splicing
5.14.	Feature Key	J_segment
	Definition	joining segment of immunoglobulin light and heavy chains, and T-cell receptor alpha, beta, and gamma chains
	Optional qualifiers	allele gene gene_synonym map note product pseudo pseudogene standard_name
	Parent Key	CDS
	Organism scope	eukaryotes
5.15.	Feature Key	LTR
	Definition	long terminal repeat, a sequence directly repeated at both ends of a defined sequence, of the sort typically found in retroviruses
	Optional qualifiers	allele function gene gene_synonym map note standard_name

5.16.	Feature Key	mat_peptide
	Definition	mature peptide or protein coding sequence; coding sequence for the mature or final peptide or protein product following post-translational modification; the location does not include the stop codon (unlike the corresponding CDS)
	Optional qualifiers	allele EC_number function gene gene_synonym map note product pseudo pseudogene standard_name
5.17.	Feature Key	misc_binding
	Definition	site in nucleic acid which covalently or non-covalently binds another moiety that cannot be described by any other binding key (primer_bind or protein_bind)
	Mandatory qualifiers	bound_moiety
	Optional qualifiers	allele function gene gene_synonym map note
	Comment	note that the feature key RBS is used for ribosome binding sites
5.18.	Feature Key	misc_difference
	Definition	featured sequence differs from the presented sequence at this location and cannot be described by any other Difference key (unsure, variation, or modified_base)
	Optional qualifiers	allele clone compare gene gene_synonym map note phenotype replace standard_name
	Comment	the misc_difference feature key should be used to describe variability introduced artificially, e.g. by genetic manipulation or by chemical synthesis; use the replace qualifier to annotate a deletion, insertion, or substitution.

5.19.	Feature Key	mi sc_feature
	Definition	region of biological interest which cannot be described by any other feature key; a new or rare feature
	Optional qualifiers	allele function gene gene_synonym map note number phenotype product pseudo pseudogene standard_name
	Comment	this key should not be used when the need is merely to mark a region in order to comment on it or to use it in another feature's location
5.20.	Feature Key	mi sc_recomb
	Definition	site of any generalized, site-specific or replicative recombination event where there is a breakage and reunion of duplex DNA that cannot be described by other recombination keys or qualifiers of source key (proviral)
	Optional qualifiers	allele gene gene_synonym map note standard_name
	Molecule scope	DNA
5.21.	Feature Key	mi sc_RNA
	Definition	any transcript or RNA product that cannot be defined by other RNA keys (prim_transcript, precursor_RNA, mRNA, 5' UTR, 3' UTR, exon, CDS, sig_peptide, transit_peptide, mat_peptide, intron, polyA_site, ncRNA, rRNA and tRNA)
	Optional qualifiers	allele function gene gene_synonym map note operon product pseudo pseudogene standard_name trans_splicing

5.22.	Feature Key	misc_signal
	Definition	any region containing a signal controlling or altering gene function or expression that cannot be described by other signal keys (promoter, CAAT_signal, TATA_signal, -35_signal, -10_signal, GC_signal, RBS, polyA_signal, enhancer, attenuator, terminator, and rep_origin)
	Optional qualifiers	allele function gene gene_synonym map note operon phenotype standard_name
5.23.	Feature Key	misc_structure
	Definition	any secondary or tertiary nucleotide structure or conformation that cannot be described by other Structure keys (stem_loop and D-loop)
	Optional qualifiers	allele function gene gene_synonym map note standard_name
5.24.	Feature Key	mobile_element
	Definition	region of genome containing mobile elements
	Mandatory qualifiers	mobile_element_type
	Optional qualifiers	allele function gene gene_synonym map note rpt_family rpt_type standard_name
5.25.	Feature Key	modified_base
	Definition	the indicated nucleotide is a modified nucleotide and should be substituted for by the indicated molecule (given in the mod_base qualifier value)
	Mandatory qualifiers	mod_base
	Optional qualifiers	allele frequency gene gene_synonym map note
	Comment	value for the mandatory mod_base qualifier is limited to the restricted vocabulary for modified base abbreviations in Section 2 of this Annex.

5.26.	Feature Key	mRNA
	Definition	messenger RNA; includes 5' untranslated region (5' UTR), coding sequences (CDS, exon) and 3' untranslated region (3' UTR)
	Optional qualifiers	allele artificial_location function gene gene_synonym map note operon product pseudo pseudogene standard_name trans_splicing
5.27.	Feature Key	ncRNA
	Definition	a non-protein-coding gene, other than ribosomal RNA and transfer RNA, the functional molecule of which is the RNA transcript
	Mandatory qualifiers	ncRNA_class
	Optional qualifiers	allele function gene gene_synonym map note operon product pseudo pseudogene standard_name trans_splicing
	Comment	the ncRNA feature is not used for ribosomal and transfer RNA annotation, for which the rRNA and tRNA feature keys should be used, respectively
5.28.	Feature Key	N_region
	Definition	extra nucleotides inserted between rearranged immunoglobulin segments
	Optional qualifiers	allele gene gene_synonym map note product pseudo pseudogene standard_name
	Parent Key	CDS
	Organism scope	eukaryotes

5.29.	Feature Key	operon
	Definition	region containing polycistronic transcript including a cluster of genes that are under the control of the same regulatory sequences/promotor and in the same biological pathway
	Mandatory qualifiers	operon
	Optional qualifiers	allele function map note phenotype pseudo pseudogene standard_name
5.30.	Feature Key	oriT
	Definition	origin of transfer; region of a DNA molecule where transfer is initiated during the process of conjugation or mobilization
	Optional qualifiers	allele bound_moiety direction gene gene_synonym map note rpt_family rpt_type rpt_unit_range rpt_unit_seq standard_name
	Molecule Scope	DNA
	Comment	rep_origin should be used for origins of replication; direction qualifier has legal values RIGHT, LEFT and BOTH, however only RIGHT and LEFT are valid when used in conjunction with the oriT feature; origins of transfer can be present in the chromosome; plasmids can contain multiple origins of transfer
5.31.	Feature Key	polyA_signal
	Definition	recognition region necessary for endonuclease cleavage of an RNA transcript that is followed by polyadenylation; consensus=AATAAA [1]
	Optional qualifiers	allele gene gene_synonym map note
	Organism scope	eukaryotes and eukaryotic viruses
	References	[1] Proudfoot, N. and Brownlee, G.G. Nature 263, 211-214 (1976)

5.32.	Feature Key	polyA_site
	Definition	site on an RNA transcript to which will be added adenine residues by post-transcriptional polyadenylation
	Optional qualifiers	allele gene gene_synonym map note
	Organism scope	eukaryotes and eukaryotic viruses
5.33.	Feature Key	precursor_RNA
	Definition	any RNA species that is not yet the mature RNA product; may include 5' untranslated region (5' UTR), coding sequences (CDS, exon), intervening sequences (intron) and 3' untranslated region (3' UTR)
	Optional qualifiers	allele function gene gene_synonym map note operon product standard_name trans_splicing
	Comment	used for RNA which may be the result of post-transcriptional processing; if the RNA in question is known not to have been processed, use the prim_transcript key
5.34.	Feature Key	prim_transcript
	Definition	primary (initial, unprocessed) transcript; includes 5' untranslated region (5' UTR), coding sequences (CDS, exon), intervening sequences (intron) and 3' untranslated region (3' UTR)
	Optional qualifiers	allele function gene gene_synonym map note operon standard_name
5.35.	Feature Key	primer_bind
	Definition	non-covalent primer binding site for initiation of replication, transcription, or reverse transcription; includes site(s) for synthetic e.g., PCR primer elements
	Optional qualifiers	allele gene gene_synonym map note standard_name PCR_conditions
	Comment	used to annotate the site on a given sequence to which a primer molecule binds - not intended to represent the sequence of the primer molecule itself; PCR components and reaction times may be stored under the PCR_conditions qualifier; since PCR reactions most often involve pairs of primers, a single primer_bind key may use the order(location,location) operator with two locations, or a pair of primer_bind keys may be used

5.36.	Feature Key	promoter
	Definition	region on a DNA molecule involved in RNA polymerase binding to initiate transcription
	Optional qualifiers	allele bound_moiety function gene gene_synonym map note operon phenotype pseudo pseudogene standard_name
	Molecule scope	DNA
5.37.	Feature Key	protein_bind
	Definition	non-covalent protein binding site on nucleic acid
	Mandatory qualifiers	bound_moiety
	Optional qualifiers	allele function gene gene_synonym map note operon standard_name
	Comment	note that RBS is used for ribosome binding sites
5.38.	Feature Key	RBS
	Definition	ribosome binding site
	Optional qualifiers	allele gene gene_synonym map note standard_name
	References	[1] Shine, J. and Dalgarno, L. Proc Natl Acad Sci USA 71, 1342-1346 (1974) [2] Gold, L. et al. Ann Rev Microb 35, 365-403 (1981)
	Comment	in prokaryotes, known as the Shine-Dalgarno sequence: is located 5 to 9 bases upstream of the initiation codon; consensus GGAGGT [1,2]

5.39.	Feature Key	repeat_region
	Definition	region of genome containing repeating units
	Optional qualifiers	allele function gene gene_synonym map note rpt_family rpt_type rpt_unit_range rpt_unit_seq satellite standard_name
5.40.	Feature Key	rep_origin
	Definition	origin of replication; starting site for duplication of nucleic acid to give two identical copies
	Optional Qualifiers	allele direction gene gene_synonym map note standard_name
	Comment	direction qualifier has valid values: RIGHT, LEFT, or BOTH
5.41.	Feature Key	rRNA
	Definition	mature ribosomal RNA; RNA component of the ribonucleoprotein particle (ribosome) which assembles amino acids into proteins
	Optional qualifiers	allele function gene gene_synonym map note operon product pseudo standard_name
	Comment	rRNA sizes should be annotated with the product qualifier

5.42.	Feature Key	S_region
	Definition	switch region of immunoglobulin heavy chains; involved in the rearrangement of heavy chain DNA leading to the expression of a different immunoglobulin class from the same B-cell
	Optional qualifiers	allele gene gene_synonym map note product pseudo pseudogene standard_name
	Parent Key	misc_signal
	Organism scope	eukaryotes
5.43.	Feature Key	sig_peptide
	Definition	signal peptide coding sequence; coding sequence for an N-terminal domain of a secreted protein; this domain is involved in attaching nascent polypeptide to the membrane leader sequence
	Optional qualifiers	allele function gene gene_synonym map note product pseudo pseudogene standard_name

5.44.	Feature Key	source
	Definition	identifies the source of the sequence; this key is mandatory; every sequence will have a single source key spanning the entire sequence
	Mandatory qualifiers	organism mol_type
	Optional qualifiers	cell_line cell_type chromosome clone clone_lib collected_by collection_date cultivar dev_stage ecotype environmental_sample germline haplogroup haplotype host identified_by isolate isolation_source lab_host lat_lon macronuclear map mating_type note organelle PCR_primers plasmid pop_variant proviral rearranged segment serotype serovar sex strain sub_clone sub_species sub_strain tissue_lib tissue_type variety
	Molecule scope	any

5.45.	Feature Key	stem_loop
	Definition	hairpin; a double-helical region formed by base-pairing between adjacent (inverted) complementary sequences in a single strand of RNA or DNA
	Optional qualifiers	allele function gene gene_synonym map note operon standard_name

5.46.	Feature Key	STS
	Definition	sequence tagged site; short, single-copy DNA sequence that characterizes a mapping landmark on the genome and can be detected by PCR; a region of the genome can be mapped by determining the order of a series of STSs
	Optional qualifiers	allele gene gene_synonym map note standard_name
	Molecule scope	DNA
	Parent key	misc_binding
	Comment	STS location to include primer(s) in primer_bind key or primers

5.47.	Feature Key	TATA_signal
	Definition	TATA box; Goldberg-Hogness box; a conserved AT-rich septamer found about 25 bp before the start point of each eukaryotic RNA polymerase II transcript unit which may be involved in positioning the enzyme for correct initiation; consensus=TATA(A or T)A(A or T) [1,2]
	Optional qualifiers	allele gene gene_synonym map note
	Organism scope	eukaryotes and eukaryotic viruses
	Molecule scope	DNA
	References	[1] Efstratiadis, A. et al. Cell 21, 653-668 (1980) [2] Corden, J., et al. "Promoter sequences of eukaryotic protein-encoding genes" Science 209, 1406-1414 (1980)

5.48.	Feature Key	telomere
	Definition	region of biological interest identified as a telomere and which has been experimentally characterized
	Optional qualifiers	note rpt_type rpt_unit_range rpt_unit_seq standard_name
	Comment	the telomere feature describes the interval of DNA that corresponds to a specific structure at the end of the linear eukaryotic chromosome which is required for the integrity and maintenance of the end; this region is unique compared to the rest of the chromosome and represents the physical end of the chromosome

5.49.	Feature Key	terminator
	Definition	sequence of DNA located either at the end of the transcript that causes RNA polymerase to terminate transcription
	Optional qualifiers	allele gene gene_synonym map note operon standard_name
	Molecule scope	DNA
5.50.	Feature Key	tmRNA
	Definition	transfer messenger RNA; tmRNA acts as a tRNA first, and then as an mRNA that encodes a peptide tag; the ribosome translates this mRNA region of tmRNA and attaches the encoded peptide tag to the C-terminus of the unfinished protein; this attached tag targets the protein for destruction or proteolysis
	Optional qualifiers	allele function gene gene_synonym map note product pseudo pseudogene standard_name tag_peptide
5.51.	Feature Key	transit_peptide
	Definition	transit peptide coding sequence; coding sequence for an N-terminal domain of a nuclear-encoded organellar protein; this domain is involved in post-translational import of the protein into the organelle
	Optional qualifiers	allele function gene gene_synonym map note product pseudo pseudogene standard_name
5.52.	Feature Key	tRNA
	Definition	mature transfer RNA, a small RNA molecule (75-85 bases long) that mediates the translation of a nucleic acid sequence into an amino acid sequence
	Optional qualifiers	allele anticodon function gene gene_synonym map note product pseudo pseudogene standard_name trans_splicing

5. 53.	Feature Key	unsure
	Definition	author is unsure of exact sequence in this region
	Optional qualifiers	allele compare gene gene_synonym map note replace
	Comment	use the replace qualifier to annotate a deletion, insertion, or substitution.
5. 54.	Feature Key	V_region
	Definition	variable region of immunoglobulin light and heavy chains, and T-cell receptor alpha, beta, and gamma chains; codes for the variable amino terminal portion; can be composed of V_segments, D_segments, N_regions, and J_segments
	Optional qualifiers	allele gene gene_synonym map note product pseudo pseudogene standard_name
	Parent Key	CDS
	Organism scope	eukaryotes
5. 55.	Feature Key	V_segment
	Definition	variable segment of immunoglobulin light and heavy chains, and T-cell receptor alpha, beta, and gamma chains; codes for most of the variable region (V_region) and the last few amino acids of the leader peptide
	Optional qualifiers	allele gene gene_synonym map note product pseudo pseudogene standard_name
	Parent Key	CDS
	Organism scope	eukaryotes

5.56.	Feature Key	variation
	Definition	a related strain contains stable mutations from the same gene (e.g., RFLPs, polymorphisms, etc.) which differ from the presented sequence at this location (and possibly others)
	Optional qualifiers	allele compare frequency gene gene_synonym map note phenotype product replace standard_name
	Comment	used to describe alleles, RFLP's, and other naturally occurring mutations and polymorphisms; variability arising as a result of genetic manipulation (e.g. site directed mutagenesis) should be described with the misc_difference feature; use the replace qualifier to annotate a deletion, insertion, or substitution
5.57.	Feature Key	3' UTR
	Definition	region at the 3' end of a mature transcript (following the stop codon) that is not translated into a protein
	Optional qualifiers	allele function gene gene_synonym map note standard_name trans_splicing
	Comment	The apostrophe character has special meaning in XML, and must be substituted with "'" in the value of an element. Thus "3' UTR" must be represented as "3'UTR" in the XML file, i.e., <INSDFeature_key>3'UTR</INSDFeature_key>.
5.58.	Feature Key	5' UTR
	Definition	region at the 5' end of a mature transcript (preceding the initiation codon) that is not translated into a protein
	Optional qualifiers	allele function gene gene_synonym map note standard_name trans_splicing
	Comment	The apostrophe character has special meaning in XML, and must be substituted with "'" in the value of an element. Thus "5' UTR" must be represented as "5'UTR" in the XML file, i.e., <INSDFeature_key>5'UTR</INSDFeature_key>.

5. 59.	Feature Key	- 10_signal
	Definition	Pribnow box; a conserved region about 10 bp upstream of the start-point of bacterial transcription units which may be involved in binding RNA polymerase; consensus=TAtAaT [1, 2, 3, 4]
	Optional qualifiers	allele gene gene_synonym map note operon standard_name
	Organism scope	prokaryotes
	Molecule scope	DNA
	References	[1] Schaller, H., Gray, C., and Hermann, K. Proc Natl Acad Sci USA 72, 737-741 (1974) [2] Pribnow, D. Proc Natl Acad Sci USA 72, 784-788 (1974) [3] Hawley, D.K. and McClure, W.R. "Compilation and analysis of Escherichia coli promoter DNA sequences" Nucl Acid Res 11, 2237-2255 (1983) [4] Rosenberg, M. and Court, D. "Regulatory sequences involved in the promotion and termination of RNA transcription" Ann Rev Genet 13, 319-353 (1979)
5. 60.	Feature Key	- 35_signal
	Definition	a conserved hexamer about 35 bp upstream of the start-point of bacterial transcription units; consensus=TTGACa or TGTGACA
	Optional qualifiers	allele gene gene_synonym map note operon standard_name
	Organism scope	prokaryotes
	Molecule scope	DNA
	References	[1] Takanami, M., et al. Nature 260, 297-302 (1976) [2] Moran, C.P., Jr., et al. Molec Gen Genet 186, 339-346 (1982) [3] Maniatis, T., et al. Cell 5, 109-113 (1975)

SECTION 6: DESCRIPTION OF QUALIFIERS FOR NUCLEIC SEQUENCES

This section contains the list of qualifiers to be used for features in nucleotide sequences. The qualifiers are listed in alphabetic order.

Where a Value format of "none" is indicated in the description of a qualifier (e.g. germline), the INSDQualifier_value element must not be used.

6.1.	Qualifier	allele
	Definition	name of the allele for the given gene
	Value format	free text
	Example	<INSDQualifier_value>adh1-1</INSDQualifier_value>
	Comment	all gene-related features (exon, CDS etc) for a given gene should share the same allele qualifier value; the allele qualifier value must, by definition, be different from the gene qualifier value; when used with the variation feature key, the allele qualifier value should be that of the variant.
6.2.	Qualifier	anticodon
	Definition	location of the anticodon of tRNA and the amino acid for which it codes
	Value format	(pos: <location>, aa: <amino_acid>, seq<text>) where location is the position of the anticodon and <amino_acid> is the abbreviation for the amino acid encoded and seq is the sequence of the anticodon
	Example	<INSDQualifier_value>(pos: 34. . 36, aa: Phe, seq: aaa)</INSDQualifier_value> <INSDQualifier_value>(pos: join(5, 495. . 496, aa: Leu, seq: taa)</INSDQualifier_value> <INSDQualifier_value>(pos: complement(4156. . 4158), aa: Glu, seq: ttg)</INSDQualifier_value>
6.3.	Qualifier	bound_moiety
	Definition	name of the molecule/complex that may bind to the given feature
	Value format	free text
	Example	<INSDQualifier_value>GAL4</INSDQualifier_value>
	Comment	Multiple bound_moiety qualifiers are legal on "promoter" and "enhancer" features. A single bound_moiety qualifier is legal on the "misc_binding", "oriT" and "protein_bind" features.
6.4.	Qualifier	cell_line
	Definition	cell line from which the sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>MCF7</INSDQualifier_value>
6.5.	Qualifier	cell_type
	Definition	cell type from which the sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>leukocyte</INSDQualifier_value>

6.6.	Qualifier	chromosome
	Definition	chromosome (e.g. Chromosome number) from which the sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>1</INSDQualifier_value> <INSDQualifier_value>X</INSDQualifier_value>
6.7.	Qualifier	clone
	Definition	clone from which the sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>lambda-hIL7.3</INSDQualifier_value>
	Comment	not more than one clone should be specified for a given source feature; where the sequence was obtained from multiple clones it may be further described in the feature table using the feature key misc_feature and a note qualifier to specify the multiple clones.
6.8.	Qualifier	clone_lib
	Definition	clone library from which the sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>lambda-hIL7</INSDQualifier_value>
6.9.	Qualifier	codon_start
	Definition	indicates the offset at which the first complete codon of a coding feature can be found, relative to the first base of that feature.
	Value format	1 or 2 or 3
	Example	<INSDQualifier_value>2</INSDQualifier_value>
6.10.	Qualifier	collected_by
	Definition	name of persons or institute who collected the specimen
	Value format	free text
	Example	<INSDQualifier_value>Dan Janzen</INSDQualifier_value>
6.11.	Qualifier	collection_date
	Definition	date that the specimen was collected
	Value format	DD-Mmm-YYYY, Mmm-YYYY or YYYY
	Example	<INSDQualifier_value>21-Oct-1952</INSDQualifier_value> <INSDQualifier_value>Oct-1952</INSDQualifier_value> <INSDQualifier_value>1952</INSDQualifier_value>
	Comment	full date format DD-Mmm-YYYY is preferred; where day and/or month of collection is not known either "Mmm-YYYY" or "YYYY" can be used; three-letter month abbreviation can be one of the following: Jan, Feb, Mar, Apr, May, Jun, Jul, Aug, Sep, Oct, Nov, Dec.

6.12.	Qualifier	compare
	Definition	Reference details of an existing public INSD entry to which a comparison is made
	Value format	[accession-number, sequence-version]
	Example	<INSDQualifier_value>AJ634337.1</INSDQualifier_value>
	Comment	This qualifier may be used on the following features: misc_difference, unsure, and variation. Multiple compare qualifiers with different contents are allowed within a single feature. This qualifier is not intended for large-scale annotation of variations, such as SNPs.
6.13.	Qualifier	cultivar
	Definition	cultivar (cultivated variety) of plant from which sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>Nipponbare</INSDQualifier_value> <INSDQualifier_value>Tenuifolius</INSDQualifier_value> <INSDQualifier_value>Candy Cane</INSDQualifier_value> <INSDQualifier_value>IR36</INSDQualifier_value>
	Comment	'cultivar' is applied solely to products of artificial selection; use the variety qualifier for natural, named plant and fungal varieties.
6.14.	Qualifier	dev_stage
	Definition	if the sequence was obtained from an organism in a specific developmental stage, it is specified with this qualifier
	Value format	free text
	Example	<INSDQualifier_value>fourth instar larva</INSDQualifier_value>
6.15.	Qualifier	direction
	Definition	direction of DNA replication
	Value format	left, right, or both where left indicates toward the 5' end of the sequence (as presented) and right indicates toward the 3' end
	Example	<INSDQualifier_value>LEFT</INSDQualifier_value>
	Comment	The values left, right, and both are permitted when the direction qualifier is used to annotate a rep_origin feature key. However, only left and right values are permitted when the direction qualifier is used to annotate an oriT feature key. The values are case-insensitive, i.e. both "RIGHT" and "right" are valid.

6.16.	Qualifier	EC_number
	Definition	Enzyme Commission number for enzyme product of sequence
	Value format	free text
	Example	<INSDQualifier_value>1.1.2.4</INSDQualifier_value> <INSDQualifier_value>1.1.2.-</INSDQualifier_value> <INSDQualifier_value>1.1.2.n</INSDQualifier_value>
	Comment	valid values for EC numbers are defined in the list prepared by the Nomenclature Committee of the International Union of Biochemistry and Molecular Biology (NC-IUBMB) (published in Enzyme Nomenclature 1992, Academic Press, San Diego, or a more recent revision thereof). The format represents a string of four numbers separated by full stops; up to three numbers starting from the end of the string can be replaced by dash "." to indicate uncertain assignment. Symbol "n" can be used in the last position instead of a number where the EC number is awaiting assignment. Please note that such incomplete EC numbers are not approved by NC-IUBMB.
6.17.	Qualifier	ecotype
	Definition	a population within a given species displaying genetically based, phenotypic traits that reflect adaptation to a local habitat
	Value Format	free text
	Example	<INSDQualifier_value>Columbia</INSDQualifier_value>
	Comment	an example of such a population is one that has adapted hairier than normal leaves as a response to an especially sunny habitat. 'Ecotype' is often applied to standard genetic stocks of Arabidopsis thaliana, but it can be applied to any sessile organism.
6.18.	Qualifier	environmental_sample
	Definition	identifies sequences derived by direct molecular isolation from a bulk environmental DNA sample (by PCR with or without subsequent cloning of the product, DGGE, or other anonymous methods) with no reliable identification of the source organism. Environmental samples include clinical samples, gut contents, and other sequences from anonymous organisms that may be associated with a particular host. They do not include endosymbionts that can be reliably recovered from a particular host, organisms from a readily identifiable but uncultured field sample (e.g., many cyanobacteria), or phytoplasmas that can be reliably recovered from diseased plants (even though these cannot be grown in axenic culture)
	Value format	none
	Comment	used only with the source feature key; source feature keys containing the environmental_sample qualifier should also contain the isolation_source qualifier. Sequences including environmental_sample must not include the strain qualifier.
6.19.	Qualifier	exception
	Definition	indicates that the coding region cannot be translated using standard biological rules
	Value format	One of the following controlled vocabulary phrases: RNA editing rearrangement required for product annotated by transcript or proteomic data
	Example	<INSDQualifier_value>RNA editing</INSDQualifier_value> <INSDQualifier_value>rearrangement required for product</INSDQualifier_value>
	Comment	only to be used to describe biological mechanisms such as RNA editing; protein translation of a CDS with an exception qualifier will be different from the according conceptual translation; must not be used where transl_except qualifier would be adequate, e.g. in case of stop codon completion use.

6.20.	Qualifier	frequency
	Definition	frequency of the occurrence of a feature
	Value format	free text representing the proportion of a population carrying the feature expressed as a fraction
	Example	<INSDQualifier_value>23/108</INSDQualifier_value> <INSDQualifier_value>1 in 12</INSDQualifier_value> <INSDQualifier_value>0.85</INSDQualifier_value>
6.21.	Qualifier	function
	Definition	function attributed to a sequence
	Value format	free text
	Example	<INSDQualifier_value>essential for recognition of cofactor </INSDQualifier_value>
	Comment	The function qualifier is used when the gene name and/or product name do not convey the function attributable to a sequence.
6.22.	Qualifier	gene
	Definition	symbol of the gene corresponding to a sequence region
	Value format	free text
	Example	<INSDQualifier_value>ilvE</INSDQualifier_value>
	Comment	Use gene qualifier to provide the gene symbol; use standard_name qualifier to provide the full gene name.
6.23.	Qualifier	gene_synonym
	Definition	synonymous, replaced, obsolete or former gene symbol
	Value format	free text
	Example	<INSDQualifier_value>Hox-3.3</INSDQualifier_value> in a feature where the gene qualifier value is Hoxc6
	Comment	used where it is helpful to indicate a gene symbol synonym; when used, a primary gene symbol must always be indicated in a gene qualifier
6.24.	Qualifier	germline
	Definition	the sequence presented has not undergone somatic rearrangement as part of an adaptive immune response; it is the unrearranged sequence that was inherited from the parental germline
	Value format	none
	Comment	germline qualifier should not be used to indicate that the source of the sequence is a gamete or germ cell; germline and rearranged qualifiers cannot be used in the same source feature; germline and rearranged qualifiers should only be used for molecules that can undergo somatic rearrangements as part of an adaptive immune response; these are the T-cell receptor (TCR) and immunoglobulin loci in the jawed vertebrates, and the unrelated variable lymphocyte receptor (VLR) locus in the jawless fish (lampreys and hagfish); germline and rearranged qualifiers should not be used outside of the Craniata (taxid=89593)
6.25.	Qualifier	haplogroup
	Definition	name for a group of similar haplotypes that share some sequence variation.

Haplogroups are often used to track migration of population groups.

	Value format	free text
	Example	<INSDQualifier_value>H* </INSDQualifier_value>
6. 26.	Qualifier	haplotype
	Definition	name for a specific set of alleles that are linked together on the same physical chromosome. In the absence of recombination, each haplotype is inherited as a unit, and may be used to track gene flow in populations.
	Value format	free text
	Example	<INSDQualifier_value>Dw3 B5 Cw1 A1</INSDQualifier_value>
6. 27.	Qualifier	host
	Definition	natural (as opposed to laboratory) host to the organism from which sequenced molecule was obtained
	Value format	free text
	Example	<INSDQualifier_value>Homo sapiens</INSDQualifier_value> <INSDQualifier_value>Homo sapiens 12 year old girl</INSDQualifier_value> <INSDQualifier_value>Rhi zobi um NGR234</INSDQualifier_value>
6. 28.	Qualifier	identified_by
	Definition	name of the expert who identified the specimen taxonomically
	Value format	free text
	Example	<INSDQualifier_value>John Burns</INSDQualifier_value>
6. 29.	Qualifier	isolate
	Definition	individual isolate from which the sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>Patient #152</INSDQualifier_value> <INSDQualifier_value>DGGE band PSBAC- 13</INSDQualifier_value>
6. 30.	Qualifier	isolation_source
	Definition	describes the physical, environmental and/or local geographical source of the biological sample from which the sequence was derived
	Value format	free text
	Examples	<INSDQualifier_value>rumen isolates from standard Pelleted ration-fed steer #67</INSDQualifier_value> <INSDQualifier_value>permanent Antarctic sea ice</INSDQualifier_value> <INSDQualifier_value>denitrifying activated sludge from carbon_limited continuous reactor</INSDQualifier_value>
	Comment	used only with the source feature key; source feature keys containing an environmental_sample qualifier should also contain an isolation_source qualifier
6. 31.	Qualifier	lab_host
	Definition	scientific name of the laboratory host used to propagate the source organism from

which the sequenced molecule was obtained

Value format	free text
Example	<INSDQualifier_value>Gallus gallus</INSDQualifier_value> <INSDQualifier_value>Gallus gallus embryo</INSDQualifier_value> <INSDQualifier_value>Escherichia coli strain DH5 alpha</INSDQualifier_value> <INSDQualifier_value>Homo sapiens HeLa cells</INSDQualifier_value>
Comment	the full binomial scientific name of the host organism should be used when known; extra conditional information relating to the host may also be included

6.32. Qualifier	lat_lon
Definition	geographical coordinates of the location where the specimen was collected
Value format	free text - degrees latitude and longitude in format "d[d.ddd] N S d[dd.ddd] W E"
Example	<INSDQualifier_value>47.94 N 28.12 W</INSDQualifier_value> <INSDQualifier_value>45.0123 S 4.1234 E</INSDQualifier_value>

6.33. Qualifier	macronuclear
Definition	if the sequence shown is DNA and from an organism which undergoes chromosomal differentiation between macronuclear and micronuclear stages, this qualifier is used to denote that the sequence is from macronuclear DNA
Value format	none

6.34. Qualifier	map
Definition	genomic map position of feature
Value format	free text
Example	<INSDQualifier_value>8q12-13</INSDQualifier_value>

6.35. Qualifier	mating_type
Definition	mating type of the organism from which the sequence was obtained; mating type is used for prokaryotes, and for eukaryotes that undergo meiosis without sexually dimorphic gametes
Value format	free text
Examples	<INSDQualifier_value>MAT-1</INSDQualifier_value> <INSDQualifier_value>plus</INSDQualifier_value> <INSDQualifier_value>-</INSDQualifier_value> <INSDQualifier_value>odd</INSDQualifier_value> <INSDQualifier_value>even</INSDQualifier_value>
Comment	mating_type qualifier values male and female are valid in the prokaryotes, but not in the eukaryotes; for more information, see the entry for the sex qualifier.

6.36.	Qualifier	mobile_element_type
	Definition	type and name or identifier of the mobile element which is described by the parent feature
	Value format	<mobile_element_type>[:<mobile_element_name>] where <mobile_element_type> is one of the following: transposon retrotransposon integron insertion sequence non-LTR retrotransposon SINE MITE LINE other
	Example	<INSDQualifier_value>transposon:Tnp9</INSDQualifier_value>
	Comment	mobile_element_type is legal on mobile_element feature key only. Mobile element should be used to represent both elements which are currently mobile, and those which were mobile in the past. Value "other" for <mobile_element_type> requires a <mobile_element_name>
6.37.	Qualifier	mod_base
	Definition	abbreviation for a modified nucleotide base
	Value format	modified base abbreviation chosen from this Annex, Table 2
	Example	<INSDQualifier_value>m5c</INSDQualifier_value> <INSDQualifier_value>OTHER</INSDQualifier_value>
	Comment	specific modified nucleotides not found in Section 2 of this Annex are annotated by entering OTHER as the value for the mod_base qualifier and including a note qualifier with the full name of the modified base as its value
6.38.	Qualifier	mol_type
	Definition	molecule type of sequence
	Value format	One chosen from the following: genomic DNA genomic RNA mRNA tRNA rRNA other RNA other DNA transcribed RNA viral cRNA unassigned DNA unassigned RNA
	Example	<INSDQualifier_value>genomic DNA</INSDQualifier_value> <INSDQualifier_value>other RNA</INSDQualifier_value>
	Comment	mol_type qualifier is mandatory on the source feature key; the value "genomic DNA" does not imply that the molecule is nuclear (e.g. organelle and plasmid DNA should be described using "genomic DNA"); ribosomal RNA genes should be described using "genomic DNA"; "rRNA" should only be used if the ribosomal RNA molecule itself has been sequenced; values "other RNA" and "other DNA" should be applied to synthetic molecules, values "unassigned DNA", "unassigned RNA" should be applied where in vivo molecule is unknown.

6. 39.	Qualifier	ncRNA_class
	Definition	a structured description of the classification of the non-coding RNA described by the ncRNA parent key
	Value format	<p>TYPE</p> <p>where TYPE is one of the following controlled vocabulary terms or phrases:</p> <p>antisense_RNA</p> <p>autocatalytically_spliced_intron</p> <p>ribozyme</p> <p>hammerhead_ribozyme</p> <p>lncRNA</p> <p>RNase_P_RNA</p> <p>RNase_MRP_RNA</p> <p>telomerase_RNA</p> <p>guide_RNA</p> <p>rasiRNA</p> <p>scrRNA</p> <p>siRNA</p> <p>miRNA</p> <p>piRNA</p> <p>snoRNA</p> <p>snRNA</p> <p>SRP_RNA"</p> <p>vault_RNA</p> <p>Y_RNA</p> <p>other</p>
	Example	<p><INSDQualifier_value>autocatalytically_spliced_intron </INSDQualifier_value></p> <p><INSDQualifier_value>siRNA</INSDQualifier_value></p> <p><INSDQualifier_value>scrRNA</INSDQualifier_value></p> <p><INSDQualifier_value>other</INSDQualifier_value></p>
	Comment	specific ncRNA types not yet in the ncRNA_class controlled vocabulary can be annotated by entering "other" as the ncRNA_class qualifier value, and providing a brief explanation of novel ncRNA_class in a note qualifier
6. 40.	Qualifier	note
	Definition	any comment or additional information
	Value format	free text
	Example	<INSDQualifier_value>A comment about the feature</INSDQualifier_value>
6. 41.	Qualifier	number
	Definition	a number to indicate the order of genetic elements (e.g. exons or introns) in the 5' to 3' direction
	Value format	free text (with no whitespace characters)
	Example	<p><INSDQualifier_value>4</INSDQualifier_value></p> <p><INSDQualifier_value>6B</INSDQualifier_value></p>
	Comment	text limited to integers, letters or combination of integers and/or letters represented as a data value that contains no whitespace characters; any additional terms should be included in a standard_name qualifier. Example: a number qualifier with a value of 2A and a standard_name qualifier with a value of long

6. 42.	Qualifier	operon
	Definition	name of the group of contiguous genes transcribed into a single transcript to which that feature belongs
	Value format	free text
	Example	<INSDQualifier_value>lac</INSDQualifier_value>
	Comment	valid only on Prokaryota-specific features
6. 43.	Qualifier	organelle
	Definition	type of membrane-bound intracellular structure from which the sequence was obtained
	Value format	One of the following controlled vocabulary terms and phrases: chromatophore hydrogenosome mitochondrion nucl eomorph plastid mitochondrion: kinetoplast plastid: chloroplast plastid: apicoplast plastid: chromoplast plastid: cyanelle plastid: leucoplast plastid: proplastid,
	Examples	<INSDQualifier_value>chromatophore</INSDQualifier_value> <INSDQualifier_value>hydrogenosome</INSDQualifier_value> <INSDQualifier_value>mitochondrion</INSDQualifier_value> <INSDQualifier_value>nucl eomorph</INSDQualifier_value> <INSDQualifier_value>plastid</INSDQualifier_value> <INSDQualifier_value>mitochondrion: kinetoplast</INSDQualifier_value> <INSDQualifier_value>plastid: chloroplast</INSDQualifier_value> <INSDQualifier_value>plastid: apicoplast</INSDQualifier_value> <INSDQualifier_value>plastid: chromoplast</INSDQualifier_value> <INSDQualifier_value>plastid: cyanelle</INSDQualifier_value> <INSDQualifier_value>plastid: leucoplast</INSDQualifier_value> <INSDQualifier_value>plastid: proplastid</INSDQualifier_value>
6. 44.	Qualifier	organism
	Definition	scientific name of the organism that provided the sequenced genetic material, if known, or the available taxonomic information if the organism is unclassified; or an indication that the sequence is a synthetic construct
	Value format	free text
	Example	<INSDQualifier_value>Homo sapiens</INSDQualifier_value>

6.45.	Qualifier	PCR_primers
	Definition	PCR primers that were used to amplify the sequence. A single /PCR_primers qualifier should contain all the primers used for a single PCR reaction. If multiple forward or reverse primers are present in a single PCR reaction, multiple sets of fwd_name/fwd_seq or rev_name/rev_seq values will be present
	Value format	[fwd_name: XXX1,]fwd_seq: xxxxx1,[fwd_name: XXX2,]fwd_seq: xxxxx2, [rev_name: YYY1,]rev_seq: yyyyy1,[rev_name: YYY2,]rev_seq: yyyyy2</INSDQualifier_value>
	Example	<INSDQualifier_value>fwd_name: C01P1, fwd_seq: ttgatttttggtcayccwgaagt, rev_name: C01R4, rev_seq: ccwvytardcctarraartgttg</INSDQualifier_value> <INSDQualifier_value>fwd_name: hoge1, fwd_seq: cgkgtgtatcttact, rev_name: hoge2, rev_seq: cg< i> i>gt;gtgtatcttact</INSDQualifier_value> <INSDQualifier_value>fwd_name: C01P1, fwd_seq: ttgatttttggtcayccwgaagt, fwd_name: C01P2, fwd_seq: gatacacaggtcayccwgaagt, rev_name: C01R4, rev_seq: ccwvytardcctarraartgttg</INSDQualifier_value>
	Comment	fwd_seq and rev_seq are both mandatory; fwd_name and rev_name are both optional. Both sequences should be presented in 5'>3' order. The sequences should be given in the symbols from Section 1 of this Annex, except for the modified bases; those must be enclosed within angle brackets < >. In XML, the angle brackets < and > must be substituted with < and > since they are reserved characters in XML.
6.46.	Qualifier	phenotype
	Definition	phenotype conferred by the feature, where phenotype is defined as a physical, biochemical or behavioural characteristic or set of characteristics
	Value format	free text
	Example	<INSDQualifier_value>erythromycin resistance</INSDQualifier_value>
6.47.	Qualifier	plasmid
	Definition	name of naturally occurring plasmid from which the sequence was obtained, where plasmid is defined as an independently replicating genetic unit that cannot be described by chromosome or segment qualifiers
	Value format	free text
	Example	<INSDQualifier_value>pC589</INSDQualifier_value>
6.48.	Qualifier	pop_variant
	Definition	name of subpopulation or phenotype of the sample from which the sequence was derived
	Value format	free text
	Example	<INSDQualifier_value>pop1</INSDQualifier_value> <INSDQualifier_value>Bear Paw</INSDQualifier_value>
6.49.	Qualifier	product
	Definition	name of the product associated with the feature, e.g. the mRNA of an mRNA feature, the polypeptide of a CDS, the mature peptide of a mat_peptide, etc.
	Value format	free text
	Example	<INSDQualifier_value>trypsinogen</INSDQualifier_value> (when qualifier appears in CDS feature) <INSDQualifier_value>trypsin</INSDQualifier_value> (when qualifier appears in mat_peptide feature) <INSDQualifier_value>XYZ neural-specific transcript</INSDQualifier_value> (when qualifier appears in mRNA feature)

6. 50.	Qualifier	protein_id
	Definition	protein sequence identification number, an integer used in a sequence listing to designate the protein sequence encoded by the coding sequence identified in the corresponding CDS feature key
	Value format	an integer greater than zero
	Example	<INSDQualifier_value>89</INSDQualifier_value>
6. 51.	Qualifier	proviral
	Definition	this qualifier is used to flag sequence obtained from a virus or phage that is integrated into the genome of another organism
	Value format	none
6. 52.	Qualifier	pseudo
	Definition	indicates that this feature is a non-functional version of the element named by the feature key
	Value format	none
	Comment	The qualifier pseudo should be used to describe non-functional genes that are not formally described as pseudogenes, e.g. CDS has no translation due to other reasons than pseudogenisation events. Other reasons may include sequencing or assembly errors. In order to annotate pseudogenes the qualifier pseudogene must be used, indicating the TYPE of pseudogene.
6. 53.	Qualifier	pseudogene
	Definition	indicates that this feature is a pseudogene of the element named by the feature key
	Value format	TYPE where TYPE is one of the following controlled vocabulary terms or phrases: processed unprocessed unitary allelic unknown
	Example	<INSDQualifier_value>processed</INSDQualifier_value> <INSDQualifier_value>unprocessed</INSDQualifier_value> <INSDQualifier_value>unitary</INSDQualifier_value> <INSDQualifier_value>allelic</INSDQualifier_value> <INSDQualifier_value>unknown</INSDQualifier_value>
	Comment	Definitions of TYPE values: processed - the pseudogene has arisen by reverse transcription of a mRNA into cDNA, followed by reintegration into the genome. Therefore, it has lost any intron/exon structure, and it might have a pseudo-polyA-tail. unprocessed - the pseudogene has arisen from a copy of the parent gene by duplication followed by accumulation of random mutation. The changes, compared to their functional homolog, include insertions, deletions, premature stop codons, frameshifts and a higher proportion of non-synonymous versus synonymous substitutions. unitary - the pseudogene has no parent. It is the original gene, which is functional in some species but disrupted in some way (indels, mutation, recombination) in another species or strain. allelic - a (unitary) pseudogene that is stable in the population but importantly it has a functional alternative allele also in the population. i.e., one strain may have the gene, another strain may have the pseudogene. MHC haplotypes have allelic pseudogenes. unknown - the submitter does not know the method of pseudogenisation.

6. 54.	Qualifier	rearranged
	Definition	the sequence presented in the entry has undergone somatic rearrangement as part of an adaptive immune response; it is not the unrearranged sequence that was inherited from the parental germline
	Value format	none
	Comment	The rearranged qualifier should not be used to annotate chromosome rearrangements that are not involved in an adaptive immune response; germline and rearranged qualifiers cannot be used in the same source feature; germline and rearranged qualifiers should only be used for molecules that can undergo somatic rearrangements as part of an adaptive immune response; these are the T-cell receptor (TCR) and immunoglobulin loci in the jawed vertebrates, and the unrelated variable lymphocyte receptor (VLR) locus in the jawless fish (lampreys and hagfish); germline and rearranged qualifiers should not be used outside of the Craniata (taxid=89593)
6. 55.	Qualifier	replace
	Definition	indicates that the sequence identified in a feature's location is replaced by the sequence shown in the qualifier's value; if no sequence (i.e., no value) is contained within the qualifier, this indicates a deletion
	Value format	free text
	Example	<INSDQualifier_value>a</INSDQualifier_value> <INSDQualifier_value></INSDQualifier_value> - for a deletion
6. 56.	Qualifier	ribosomal_slippage
	Definition	during protein translation, certain sequences can program ribosomes to change to an alternative reading frame by a mechanism known as ribosomal slippage
	Value format	none
	Comment	a join operator, e.g.: [join(486..1784,1787..4810)] should be used in the CDS spans to indicate the location of ribosomal_slippage
6. 57.	Qualifier	rpt_family
	Definition	type of repeated sequence; "Alu" or "Kpn", for example
	Value format	free text
	Example	<INSDQualifier_value>Alu</INSDQualifier_value>

6. 58.	Qualifier	rpt_type
	Definition	organization of repeated sequence
	Value format	One of the following controlled vocabulary terms: tandem inverted flanking terminal direct dispersed other
	Example	<INSDQualifier_value>INVERTED</INSDQualifier_value>
	Comment	the values are case-insensitive, i.e. both "INVERTED" and "inverted" are valid; Definitions of the values: tandem - a repeat that exists adjacent to another in the same orientation; inverted - a repeat which occurs as part of a set (normally a part) organized in the reverse orientation; flanking - a repeat lying outside the sequence for which it has functional significance (eg. transposon insertion target sites); terminal - a repeat at the ends of and within the sequence for which it has functional significance (eg. transposon LTRs); direct - a repeat that exists not always adjacent but is in the same orientation; dispersed - a repeat that is found dispersed throughout the genome; other - a repeat exhibiting important attributes that cannot be described by other values.
6. 59.	Qualifier	rpt_unit_range
	Definition	location (range) of a repeating unit
	Value format	<base_range> - where <base_range> is the first and last base (separated by two dots) of a repeating unit
	Example	<INSDQualifier_value>202..245</INSDQualifier_value>
	Comment	used to indicate the base range of the sequence that constitutes a repeating unit within the region specified by the feature keys oriT and repeat_region.
6. 60.	Qualifier	rpt_unit_seq
	Definition	identity of a repeat sequence
	Value format	free text
	Example	<INSDQualifier_value>aagggc</INSDQualifier_value> <INSDQualifier_value>ag(5)tg(8)</INSDQualifier_value> <INSDQualifier_value>(AAAGA)6(AAAA)1(AAAGA)12</INSDQualifier_value>
	Comment	used to indicate the literal sequence that constitutes a repeating unit within the region specified by the feature keys oriT and repeat_region

6. 61.	Qualifier	satellite
	Definition	identifier for a satellite DNA marker, compose of many tandem repeats (identical or related) of a short basic repeated unit
	Value format	<satellite_type>[:<class>][<identifier>] - where <satellite_type> is one of the following: satellite; microsatellite; minisatellite
	Example	<INSDQualifier_value>satellite: S1a</INSDQualifier_value> <INSDQualifier_value>satellite: alpha</INSDQualifier_value> <INSDQualifier_value>satellite: gamma III</INSDQualifier_value> <INSDQualifier_value>microsatellite: DC130</INSDQualifier_value>
	Comment	many satellites have base composition or other properties that differ from those of the rest of the genome that allows them to be identified.
6. 62.	Qualifier	segment
	Definition	name of viral or phage segment sequenced
	Value format	free text
	Example	<INSDQualifier_value>6</INSDQualifier_value>
6. 63.	Qualifier	serotype
	Definition	serological variety of a species characterized by its antigenic properties
	Value format	free text
	Example	<INSDQualifier_value>B1</INSDQualifier_value>
	Comment	used only with the source feature key; the Bacteriological Code recommends the use of the term 'serovar' instead of 'serotype' for the prokaryotes; see the International Code of Nomenclature of Bacteria (1990 Revision) Appendix 10. B "Infraspecific Terms".
6. 64.	Qualifier	serovar
	Definition	serological variety of a species (usually a prokaryote) characterized by its antigenic properties
	Value format	free text
	Example	<INSDQualifier_value>0157: H7</INSDQualifier_value>
	Comment	used only with the source feature key; the Bacteriological Code recommends the use of the term 'serovar' instead of 'serotype' for prokaryotes; see the International Code of Nomenclature of Bacteria (1990 Revision) Appendix 10. B "Infraspecific Terms".

6. 65.	Qualifier	sex
	Definition	sex of the organism from which the sequence was obtained; sex is used for eukaryotic organisms that undergo meiosis and have sexually dimorphic gametes
	Value format	free text
	Examples	<code><INSDQualifier_value>female</INSDQualifier_value></code> <code><INSDQualifier_value>male</INSDQualifier_value></code> <code><INSDQualifier_value>hermaphrodite</INSDQualifier_value></code> <code><INSDQualifier_value>unisexual</INSDQualifier_value></code> <code><INSDQualifier_value>bisexual</INSDQualifier_value></code> <code><INSDQualifier_value>asexual</INSDQualifier_value></code> <code><INSDQualifier_value>monoecious</INSDQualifier_value></code> [or monecious] <code><INSDQualifier_value>dioecious</INSDQualifier_value></code> [or diecious]
	Comment	The sex qualifier should be used (instead of <code>mating_type</code> qualifier) in the Metazoa, Embryophyta, Rhodophyta & Phaeophyceae; <code>mating_type</code> qualifier should be used (instead of sex qualifier) in the Bacteria, Archaea & Fungi; neither sex nor <code>mating_type</code> qualifiers should be used in the viruses; outside of the taxa listed above, <code>mating_type</code> qualifier should be used unless the value of the qualifier is taken from the vocabulary given in the examples above
6. 66.	Qualifier	standard_name
	Definition	accepted standard name for this feature
	Value format	free text
	Example	<code><INSDQualifier_value>dotted</INSDQualifier_value></code>
	Comment	use <code>standard_name</code> qualifier to give full gene name, but use gene qualifier to give gene symbol (in the above example gene qualifier value is Dt).
6. 67.	Qualifier	strain
	Definition	strain from which sequence was obtained
	Value format	free text
	Example	<code><INSDQualifier_value>BALB/c</INSDQualifier_value></code>
	Comment	entries including strain qualifier must not include the <code>environmental_sample</code> qualifier
6. 68.	Qualifier	sub_clone
	Definition	sub-clone from which sequence was obtained
	Value format	free text
	Example	<code><INSDQualifier_value>lambda-hIL7.20g</INSDQualifier_value></code>
	Comment	not more than one <code>sub_clone</code> should be specified for a given source feature; to indicate that the sequence was obtained from multiple sub-clones, multiple source features should be given
6. 69.	Qualifier	sub_species
	Definition	name of sub-species of organism from which sequence was obtained
	Value format	free text
	Example	<code><INSDQualifier_value>lactis</INSDQualifier_value></code>

6. 70.	Qualifier	sub_strain
	Definition	name or identifier of a genetically or otherwise modified strain from which sequence was obtained, derived from a parental strain (which should be annotated in the strain qualifier). sub_strain from which sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>abis</INSDQualifier_value>
	Comment	If the parental strain is not given, this should be annotated in the strain qualifier instead of sub_strain. For example, either a strain qualifier with the value K-12 and a substrain qualifier with the value MG1655 or a strain qualifier with the value MG1655
6. 71.	Qualifier	tag_peptide
	Definition	base location encoding the polypeptide for proteolysis tag of tmRNA and its termination codon
	Value format	<base_range> - where <base_range> provides the first and last base (separated by two dots) of the location for the proteolysis tag
	Example	<INSDQualifier_value>90..122</INSDQualifier_value>
	Comment	it is recommended that the amino acid sequence corresponding to the tag_peptide be annotated by describing a 5' partial CDS feature; e.g. CDS with a location of <90..122
6. 72.	Qualifier	tissue_lib
	Definition	tissue library from which sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>tissue library 772</INSDQualifier_value>
6. 73.	Qualifier	tissue_type
	Definition	tissue type from which the sequence was obtained
	Value format	free text
	Example	<INSDQualifier_value>liver</INSDQualifier_value>

6. 74.	Qualifier	transl_except
	Definition	translational exception: single codon the translation of which does not conform to genetic code defined by organism or transl_table.
	Value format	(pos: location, aa: <amino_acid>) where <amino_acid> is the amino acid coded by the codon at the base_range position
	Example	<INSDQualifier_value>(pos: 213. . 215, aa: Trp) </INSDQualifier_value> <INSDQualifier_value>(pos: 462. . 464, aa: OTHER) </INSDQualifier_value> <INSDQualifier_value>(pos: 1017, aa: TERM) </INSDQualifier_value> <INSDQualifier_value>(pos: 2000. . 2001, aa: TERM) </INSDQualifier_value> <INSDQualifier_value>(pos: X22222: 15. . 17, aa: Ala) </INSDQualifier_value>
	Comment	if the amino acid is not one of the specific amino acids listed in Section 3 of this Annex, use OTHER as <amino_acid> and provide the name of the unusual amino acid in a note qualifier; for modified amino-acid selenocysteine use three letter code 'Sec' (one letter code 'U' in amino-acid sequence) for <amino_acid>; for partial termination codons where TAA stop codon is completed by the addition of 3' A residues to the mRNA either a single base_position or a base_range is used for the location, see the third and fourth examples above, in conjunction with a note qualifier indicating 'stop codon completed by the addition of 3' A residues to the mRNA'.
6. 75.	Qualifier	transl_table
	Definition	definition of genetic code table used if other than universal or standard genetic code table. Tables used are described in this Annex
	Value format	<integer> where <integer> is the number assigned to the genetic code table
	Example	<INSDQualifier_value>3</INSDQualifier_value> - example where the yeast mitochondrial code is to be used
	Comment	if the transl_table qualifier is not used to further annotate a CDS feature key, then the CDS is translated using the Standard Code (i.e. Universal Genetic Code). Genetic code exceptions outside the range of specified tables are reported in transl_except qualifiers.
6. 76.	Qualifier	trans_splicing
	Definition	indicates that exons from two RNA molecules are ligated in intermolecular reaction to form mature RNA
	Value format	none
	Comment	should be used on features such as CDS, mRNA and other features that are produced as a result of a trans-splicing event. This qualifier should be used only when the splice event is indicated in the "join" operator, e.g. join(complement(69611. . 69724), 139856. . 140087)
6. 77.	Qualifier	translation
	Definition	one-letter abbreviated amino acid sequence derived from either the standard (or universal) genetic code or the table as specified in a transl_table qualifier and as determined by an exception in the transl_except qualifier
	Value format	contiguous string of one-letter amino acid abbreviations from Section 3 of this Annex, "X" is to be used for AA exceptions.
	Example	<INSDQualifier_value>MASTFPPWYRGCASTPSLKGLIMCTW</INSDQualifier_value>
	Comment	to be used with CDS feature only; must be accompanied by protein_id qualifier when the translation product contains four or more amino acids; see transl_table for definition and location of genetic code Tables; only one of the qualifiers translation, pseudo and pseudogene are permitted to further annotate a CDS feature.

6.78.	Qualifier	variety
	Definition	variety (= varietas, a formal Linnaean rank) of organism from which sequence was derived.
	Value format	free text
	Example	<INSDQualifier_value>insularis</INSDQualifier_value>
	Comment	use the cultivar qualifier for cultivated plant varieties, i.e., products of artificial selection; varieties other than plant and fungal variatas should be annotated via a note qualifier, e.g. with the value <INSDQualifier_value>breed: Cukorova</INSDQualifier_value>

SECTION 7: FEATURE KEYS FOR AMINO ACID SEQUENCES

This section contains the list of allowed feature keys to be used for amino acid sequences. The feature keys are listed in alphabetic order.

7.1.	Feature Key	ACT_SITE
	Definition	Amino acid(s) involved in the activity of an enzyme
	Optional qualifiers	NOTE
	Comment	Each amino acid residue of the active site should be annotated separately with the ACT_SITE feature key. The corresponding amino acid residue number should be provided as the location descriptor in the feature location element.
7.2.	Feature Key	BINDING
	Definition	Binding site for any chemical group (co-enzyme, prosthetic group, etc.). The chemical nature of the group is indicated in the NOTE qualifier
	Mandatory qualifiers	NOTE
	Comment	Examples of values for the "NOTE" qualifier: "Heme (covalent)" and "Chloride." Where appropriate, the features keys CA_BIND, DNA_BIND, METAL, and NP_BIND should be used rather than BINDING.
7.3.	Feature Key	CA_BIND
	Definition	Extent of a calcium-binding region
	Optional qualifiers	NOTE
7.4.	Feature Key	CARBOHYD
	Definition	Glycosylation site
	Mandatory qualifiers	NOTE
	Comment	This key describes the occurrence of the attachment of a glycan (mono- or polysaccharide) to a residue of the protein. If the nature of the reducing terminal sugar is known, its abbreviation is shown between parentheses. If three dots '...' follow the abbreviation this indicates an extension of the carbohydrate chain. Conversely no dots means that a monosaccharide is linked. The type of linkage (C-, N- or O-linked) to the protein is indicated in the "NOTE" qualifier. Examples of values used in the "NOTE" qualifier: O-linked (GlcNAc); C-linked (Man); N-linked (GlcNAc...); and O-linked (Glc...).

7.5.	Feature Key	CHAIN
	Definition	Extent of a polypeptide chain in the mature protein
	Optional qualifiers	NOTE
7.6.	Feature Key	COILED
	Definition	Extent of a coiled-coil region
	Optional qualifiers	NOTE
7.7.	Feature Key	COMBIAS
	Definition	Extent of a compositionally biased region
	Optional qualifiers	NOTE
7.8.	Feature Key	CONFLICT
	Definition	Different sources report differing sequences.
	Optional qualifiers	NOTE
7.9.	Feature Key	CROSSLNK
	Definition	Post translationally formed amino acid bonds.
	Mandatory qualifiers	NOTE
	Comment	Covalent linkages of various types formed between two proteins (interchain cross-links) or between two parts of the same protein (intrachain cross-links); except for cross-links formed by disulfide bonds, for which the "DISULFID" feature key is to be used. For an interchain cross-link, the location descriptor in the feature location element is the residue number of the amino acid cross-linked to the other protein. For an intrachain cross-link, the location descriptors in the feature location element are the residue numbers of the cross-linked amino acids in conjunction with the "join" location operator, e.g. "join(42,50)." The NOTE qualifier indicates the nature of the cross-link; at least specifying the name of the conjugate and the identity of the two amino acids involved. Examples of values for the "NOTE" qualifier: "Isoglutamyl cysteine thioester (Cys-Gln);" "Beta-methylanthionine (Cys-Thr);" and "Glycyl lysine isopeptide (Lys-Gly) (interchain with G-Cter in ubiquitin)"
7.10.	Feature Key	DISULFID
	Definition	Disulfide bond
	Optional qualifiers	NOTE
	Comment	For an interchain disulfide bond, the location descriptor in the feature location element is the residue number of the cysteine linked to the other protein. For an intrachain cross-link, the location descriptors in the feature location element are the residue numbers of the linked cysteines in conjunction with the "join" location operator, e.g. "join(42,50)". For interchain disulfide bonds, the NOTE qualifier indicates the nature of the cross-link, by identifying the other protein, for example, "Interchain (between A and B chains)"

7.11.	Feature Key	DNA_BIND
	Definition	Extent of a DNA-binding region
	Mandatory qualifiers	NOTE
	Comment	The nature of the DNA-binding region is given in the NOTE qualifier. Examples of values for the "NOTE" qualifier: "Homeobox" and "Myb 2"
7.12.	Feature Key	DOMAIN
	Definition	Extent of a domain, which is defined as a specific combination of secondary structures organized into a characteristic three-dimensional structure or fold
	Mandatory qualifiers	NOTE
	Comment	The domain type is given in the NOTE qualifier. Where several copies of a domain are present, the domains are numbered. Examples of values for the "NOTE" qualifier: "Ras-GAP" and "Cadherin 1"
7.13.	Feature Key	HELIX
	Definition	Secondary structure: Helices, for example, Alpha-helix; 3(10) helix; or Pi-helix
	Optional qualifiers	NOTE
	Comment	This feature is used only for proteins whose tertiary structure is known. Only three types of secondary structure are specified: helices (key HELIX), beta-strands (key STRAND) and turns (key TURN). Residues not specified in one of these classes are in a 'loop' or 'random-coil' structure.
7.14.	Feature Key	INIT_MET
	Definition	Initiator methionine
	Optional qualifiers	NOTE
	Comment	The location descriptor in the feature location element is "1". This feature key indicates the N-terminal methionine is cleaved off. This feature is not used when the initiator methionine is not cleaved off.
7.15.	Feature Key	INTRAMEM
	Definition	Extent of a region located in a membrane without crossing it
	Optional qualifiers	NOTE
7.16.	Feature Key	LIPID
	Definition	Covalent binding of a lipid moiety
	Mandatory qualifiers	NOTE
	Comment	The chemical nature of the bound lipid moiety is given in the NOTE qualifier, indicating at least the name of the lipidated amino acid. Examples of values for the "NOTE" qualifier: "N-myristoyl glycine"; "GPI-anchor amidated serine" and "S-diacylglycerol cysteine."

7.17.	Feature Key	METAL
	Definition	Binding site for a metal ion.
	Mandatory qualifiers	NOTE
	Comment	The NOTE qualifier indicates the nature of the metal. Examples of values for the "NOTE" qualifier: "Iron; catalytic" and "Copper".
7.18.	Feature Key	MOD_RES
	Definition	Posttranslational modification of a residue
	Mandatory qualifiers	NOTE
	Comment	The chemical nature of the modified residue is given in the NOTE qualifier, indicating at least the name of the post-translationally modified amino acid. If the modified amino acid is listed in Table 4 of this Annex, the abbreviation may be used in place of the the full name. Examples of values for the "NOTE" qualifier: "N-acetylalanine"; "3-Hyp"; and "MeLys" or "N-6-methyllysine"
7.19.	Feature Key	MOTIF
	Definition	Short (up to 20 amino acids) sequence motif of biological interest
	Optional qualifiers	NOTE
7.20.	Feature Key	MUTAGEN
	Definition	Site which has been experimentally altered by mutagenesis
	Optional qualifiers	NOTE
7.21.	Feature Key	NON_STD
	Definition	Non-standard amino acid
	Optional qualifiers	NOTE
	Comment	This key describes the occurrence of non-standard amino acids selenocysteine (U) and pyrrolysine (O) in the amino acid sequence.
7.22.	Feature Key	NON_TER
	Definition	The residue at an extremity of the sequence is not the terminal residue
	Optional qualifiers	NOTE
	Comment	If applied to position 1, this means that the first position is not the N-terminus of the complete molecule. If applied to the last position, it means that this position is not the C-terminus of the complete molecule.
7.23.	Feature Key	NP_BIND
	Definition	Extent of a nucleotide phosphate-binding region
	Mandatory qualifiers	NOTE
	Comment	The nature of the nucleotide phosphate is indicated in the NOTE qualifier. Examples of values for the "NOTE" qualifier: "ATP" and "FAD".

7.24.	Feature Key	PEPTIDE
	Definition	Extent of a released active peptide
	Optional qualifiers	NOTE
7.25.	Feature Key	PROPEP
	Definition	Extent of a propeptide
	Optional qualifiers	NOTE
7.26.	Feature Key	REGION
	Definition	Extent of a region of interest in the sequence
	Optional qualifiers	NOTE
7.27.	Feature Key	REPEAT
	Definition	Extent of an internal sequence repetition
	Optional qualifiers	NOTE
7.28.	Feature Key	SIGNAL
	Definition	Extent of a signal sequence (prepeptide)
	Optional qualifiers	NOTE
7.29.	Feature Key	SITE
	Definition	Any interesting single amino-acid site on the sequence that is not defined by another feature key. It can also apply to an amino acid bond which is represented by the positions of the two flanking amino acids
	Mandatory qualifier	NOTE
	Comment	When SITE is used to annotate a modified amino acid the value for the qualifier "NOTE" must either be an abbreviation set forth in Section 4 of this Annex, Table 4, or the complete, unabbreviated name of the modified amino acid.
7.30.	Feature Key	SOURCE
	Definition	Identifies the source of the sequence; this key is mandatory; every sequence will have a single SOURCE feature spanning the entire sequence
	Mandatory qualifiers	MOL_TYPE ORGANISM
	Optional qualifiers	NOTE

7.31.	Feature Key	STRAND
	Definition	Secondary structure: Beta-strand; for example Hydrogen bonded beta-strand or residue in an isolated beta-bridge
	Optional qualifiers	NOTE
	Comment	This feature is used only for proteins whose tertiary structure is known. Only three types of secondary structure are specified: helices (key HELIX), beta-strands (key STRAND) and turns (key TURN). Residues not specified in one of these classes are in a 'loop' or 'random-coil' structure.
7.32.	Feature Key	TOPO_DOM
	Definition	Topological domain
	Optional qualifiers	NOTE
7.33.	Feature Key	TRANSMEM
	Definition	Extent of a transmembrane region
	Optional qualifiers	NOTE
7.34.	Feature Key	TRANSIT
	Definition	Extent of a transit peptide (mitochondrion, chloroplast, thylakoid, cyanelle, peroxisome etc.)
	Optional qualifiers	NOTE
7.35.	Feature Key	TURN
	Definition	Secondary structure Turns, for example, H-bonded turn (3-turn, 4-turn or 5-turn)
	Optional qualifiers	NOTE
	Comment	This feature is used only for proteins whose tertiary structure is known. Only three types of secondary structure are specified: helices (key HELIX), beta-strands (key STRAND) and turns (key TURN). Residues not specified in one of these classes are in a 'loop' or 'random-coil' structure.
7.36.	Feature Key	UNSURE
	Definition	Uncertainties in the amino acid sequence
	Optional qualifiers	NOTE
	Comment	Used to describe region(s) of an amino acid sequence for which the authors are unsure about the sequence presentation.
7.37.	Feature Key	VARIANT
	Definition	Authors report that sequence variants exist.
	Optional qualifiers	NOTE

7.38.	Feature Key	VAR_SEQ
	Definition	Description of sequence variants produced by alternative splicing, alternative promoter usage, alternative initiation and ribosomal frameshifting
	Optional qualifiers	NOTE

7.39.	Feature Key	ZN_FING
	Definition	Extent of a zinc finger region
	Mandatory qualifiers	NOTE
	Comment	The type of zinc finger is indicated in the NOTE qualifier. For example: "GATA-type" and "NR C4-type"

SECTION 8: QUALIFIERS FOR AMINO ACID SEQUENCES

This section contains the list of allowed qualifiers to be used for amino acid sequences.

8.1.	Qualifier	MOL_TYPE
	Definition	In vivo molecule type of sequence
	Value format	protein
	Example	<INSDQualifier_value>protein</INSDQualifier_value>
	Comment	The "MOL_TYPE" qualifier is mandatory on the SOURCE feature key.

8.2.	Qualifier	NOTE
	Definition	Any comment or additional information
	Value format	free text
	Example	<INSDQualifier_value>Heme (covalent)</INSDQualifier_value>
	Comment	The "NOTE" qualifier is mandatory for the feature keys: BINDING; CARBOHYD; CROSSLNK; DISULFID; DNA_BIND; DOMAIN; LIPID; METAL; MOD_RES; NP_BIND and ZN_FING

8.3.	Qualifier	ORGANISM
	Definition	Scientific name of the organism that provided the peptide
	Value format	free text
	Example	<INSDQualifier_value>Homo sapiens</INSDQualifier_value>
	Comment	The "ORGANISM" qualifier is mandatory for the SOURCE feature key.

SECTION 9: GENETIC CODES TABLES

Table 5 reproduces Genetic Code Tables to be used for translating coding sequences. The value for the trans_table qualifier is the number assigned to the corresponding genetic code table. Where a CDS feature is described with a translation qualifier but not a transl_table qualifier, the 1 - Standard Code is used by default for translation. (Note: Genetic code tables 7, 8, and 17 to 20 do not exist, therefore these numbers do not appear in Table 5.)

Table 5: Genetic Code Tables

[illegible]

[illegible]

[illegible]

[Annex II to ST.26 follows]

ST.26 - ANNEX II

DOCUMENT TYPE DEFINITION FOR SEQUENCE LISTING (DTD)

Final Draft

Proposal presented by the SEQL Task Force for consideration and adoption at the CWS/4

```
<?xml version="1.0" encoding="UTF-8"?>
<!--Annex II of ST.26, Document Type Definition (DTD) for Sequence Listing

This entity may be identified by the PUBLIC identifier:
*****
PUBLIC "-//WIPO//DTD SEQUENCE LISTING 1.0//EN" "ST26SequenceListing_V1_0.dtd"
*****

*****

* PUBLIC DTD URL

* http://www.wipo.int/standards/DTD/ST26SequenceListing_V1_0.dtd
*****

Recommended Standard for the presentation of nucleotide and amino acid sequence listings
using XML (eXtensible Markup Language)

*****
* CONTACTS
*****

xml.standards@wipo.int

Date draft created: 2014-03-11

*****
* NOTES
*****
The sequence data part is a subset of the complete INSDC DTD that only covers
the requirements of WIPO Standard ST.26.

*****
* REVISION HISTORY
*****
2014-03-11

Final draft for adoption.
*****

ST26SequenceListing
*****
* ROOT ELEMENT
*****
-->
<!ELEMENT ST26SequenceListing ((ApplicantFileReference | (
    ApplicationIdentification,ApplicantFileReference?)),
    EarliestPriorityApplicationIdentification?,(ApplicantName,
    ApplicantNameLatin?)?,(InventorName,InventorNameLatin?)?,
    InventionTitle+,SequenceTotalQuantity,SequenceData+) >

<!--The elements ApplicantName and InventorName are optional in this DTD to facilitate
the conversion between various encoding schemes-->
<!ATTLIST ST26SequenceListing
    dtdVersion CDATA #REQUIRED
    fileName CDATA #IMPLIED
    softwareName CDATA #IMPLIED
    softwareVersion CDATA #IMPLIED
    productionDate CDATA #IMPLIED >

<!--ApplicantFileReference
```


Applicant's or agent's file reference, mandatory if application identification not provided.

-->

<!ELEMENT ApplicantFileReference (#PCDATA) >

<!--ApplicationIdentification
Application identification for which the sequence listing is submitted, when available.
-->

<!ELEMENT ApplicationIdentification (IPOfficeCode?,ApplicationNumberText,
FilingDate?) >

<!--EarliestPriorityApplicationIdentification
Application identification of the earliest claimed priority, which Contains IPOfficeCode,
ApplicationNumberText and FilingDate elements.
-->

<!ELEMENT EarliestPriorityApplicationIdentification (IPOfficeCode?,
ApplicationNumberText,FilingDate?) >

<!--ApplicantName
The name of the first mentioned applicant in characters set forth in paragraph 40 a) of the
ST.26 main body document.
-->

<!--languageCode: Appropriate language code from ISO 639-1 - Codes for the representation
of names of languages - Part 1: Alpha-2
-->

<!ELEMENT ApplicantName (#PCDATA) >

<!ATTLIST ApplicantName
languageCode CDATA #REQUIRED >

<!--ApplicantNameLatin
Where ApplicantName is typed in characters other than those as set forth in paragraph 40
b), a translation or transliteration of the name of the first mentioned applicant must also
be typed in characters as set forth in paragraph 40 b).
-->

<!ELEMENT ApplicantNameLatin (#PCDATA) >

<!--InventorName
Name of the first mentioned inventor typed in the characters as set forth in paragraph 40
a).-->

<!--languageCode: Appropriate language code from ISO 639-1 - Codes for the representation
of names of languages - Part 1: Alpha-2
-->

<!ELEMENT InventorName (#PCDATA) >

<!ATTLIST InventorName
languageCode CDATA #REQUIRED >

<!--InventorNameLatin
Where InventorName is typed in characters other than those as set forth in paragraph 40 b),
a translation or transliteration of the first mentioned inventor may also be typed in
characters as set forth in paragraph 40 b).
-->

<!ELEMENT InventorNameLatin (#PCDATA) >

<!--InventionTitle
Title of the invention typed in the characters as set forth in paragraph 40 a) in the
language of filing. A translation of the title of the invention into additional languages
may be typed in the characters as set forth in paragraph 40 a) using additional
InventionTitle elements. Preferably two to seven words.
-->

<!--languageCode: Appropriate language code from ISO 639-1 - Codes
for the representation of names of languages - Part 1: Alpha-2
-->

<!ELEMENT InventionTitle (#PCDATA) >

<!ATTLIST InventionTitle
languageCode CDATA #REQUIRED >

<!--SequenceTotalQuantity
Indicates the total number of sequences in the document.
Its purpose is to be quickly accessible for automatic processing.
-->

<!ELEMENT SequenceTotalQuantity (#PCDATA) >

<!--SequenceData
Data for individual Sequence.

For intentionally skipped sequences see the ST.26 main body document.

```
-->
<!--ELEMENT SequenceData (INSDSeq) >
<!--ATTLIST SequenceData
        sequenceIDNumber CDATA #REQUIRED >

<!--IPOfficeCode
ST.3 code. For example, if the application identification is PCT/IB2013/099999, then
IPOfficeCode value will be IB.
-->
<!--ELEMENT IPOfficeCode (#PCDATA) >

<!--ApplicationNumberText
The application identification as provided by the office of filing (eg. PCT/IB2013/099999)
-->
<!--ELEMENT ApplicationNumberText (#PCDATA) >
```

```
<!--FilingDate
The date of filing of the patent application for which the sequence listing is submitted
ST.2 format (paragraphs 7 (a) and 11) "CCYY-MM-DD", using a 4-digit calendar year, a 2-
digit calendar month and a 2-digit day within the calendar month, e.g., 2015-01-31
-->
<!--ELEMENT FilingDate (#PCDATA) >
```

```
<!--*****
* INSD Part
*****
```

The purpose of the INSD part of this DTD is to define a customized DTD for sequence listings to support the work of IP offices while facilitating the data exchange with the public repositories.

The INSD part is subset of the INSD DTD v1.4 and as such can only be used to generate an XML instance as it will not support the complete INSD structure.

This part is based on:

The International Nucleotide Sequence Database (INSD) collaboration.

INSDSeq provides the elements of a sequence as presented in the GenBank/EMBL/DDBJ-style flatfile formats. Not all elements are used here.

```
-->

<!--INSDSeq
Sequence data.
-->
<!--ELEMENT INSDSeq (INSDSeq_length,INSDSeq_moltype,INSDSeq_division,
        INSDSeq_other-seqids?,INSDSeq_feature-table?,INSDSeq_sequence) >

<!--INSDSeq_length
-->
<!--ELEMENT INSDSeq_length (#PCDATA) >

<!--INSDSeq_moltype
Admissible values: DNA, RNA, AA
-->
<!--ELEMENT INSDSeq_moltype (#PCDATA) >

<!--INSDSeq_division
Indication that a sequence is related to a patent application. Must be populated with the
value PAT.
-->
<!--ELEMENT INSDSeq_division (#PCDATA) >

<!--INSDSeq_other-seqids
In the context of data exchange with database providers, the Patent Offices should populate
for each sequence the element INSDSeq_other-seqids with one INSDSeqid containing a
reference to the corresponding published patent and the sequence identification.
-->
<!--ELEMENT INSDSeq_other-seqids (INSDSeqid?) >

<!--INSDSeq_feature-table
Information on the location and roles of various regions within a particular sequence.
Whenever the element INSDSeq_feature-table is used, it must contain at least one feature.
```

```
-->
<!--INSDSeq_feature-table (INSDFeature+) >

<!--INSDSeq_sequence
The residues of the sequence. The sequence must not contain numbers, punctuation or
whitespace characters.
-->
<!--INSDSeqid
Intended for the use of Patent Offices in data exchange only.

Format:
pat|{office code}|{publication number}|{document kind code}|{Sequence identification
number}

where office code is the code of the IP office publishing the patent document, publication
number is the publication number of the application or patent, document kind code is the
letter codes to distinguish patent documents as defined in ST.16 and Sequence
identification number is the number of the sequence in that application or patent

Example:
pat|WO|2013999999|A1|123456

This represents the 123456th sequence from WO patent publication No. 2013999999 (A1)
-->
<!--INSDFeature
Description of one feature.
-->
<!--INSDFeature_key
A word or abbreviation indicating a feature.
-->
<!--INSDFeature_location
Region of the presented sequence which corresponds to the feature.
-->
<!--INSDFeature_qualifiers
List of qualifiers containing auxiliary information about a feature.
-->
<!--INSDQualifier
Additional information about a feature.
For coding sequences and variants see the ST.26 main body document.
-->
<!--INSDQualifier_name
Name of the qualifier.
-->
<!--INSDQualifier_value
Value of the qualifier.
-->
```

ST.26 - ANNEX III

SEQUENCE LISTING SPECIMEN (XML file)

Final Draft

Proposal presented by the SEQL Task Force for consideration and adoption at the CWS/4

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE ST26SequenceListing PUBLIC "-//WIPO//DTD SEQUENCE LISTING 1.0//EN"
ST26SequenceListing_V1_0.dtd">
<ST26SequenceListing dtdVersion="V1_0" fileName="AnnexIII_Sequence_Listing_Specimen.xml"
softwareName="SEQL-software-name" softwareVersion="1.0" productionDate="2013-12-17">
  <ApplicationIdentification>
    <IPOfficeCode>IB</IPOfficeCode>
    <ApplicationNumberText>PCT/IB2015/099999</ApplicationNumberText>
    <FilingDate>2015-01-31</FilingDate>
  </ApplicationIdentification>
  <ApplicantFileReference>AB123</ApplicantFileReference>
  <EarliestPriorityApplicationIdentification>
    <IPOfficeCode>IB</IPOfficeCode>
    <ApplicationNumberText>PCT/IB2014/111111</ApplicationNumberText>
    <FilingDate>2014-01-30</FilingDate>
  </EarliestPriorityApplicationIdentification>
  <ApplicantName languageCode="JA">出願製薬株式会社</ApplicantName>
  <ApplicantNameLatin>Shutsugan Pharmaceuticals Kabushiki Kaisha</ApplicantNameLatin>
  <InventorName languageCode="JA">特許 太郎</InventorName>
  <InventorNameLatin>Taro Tokkyo</InventorNameLatin>
  <InventionTitle languageCode="JA">efgタンパク質のためのマウスabcd-1遺伝子</InventionTitle>
  <InventionTitle languageCode="EN">Mus musculus abcd-1 gene for efg protein
  </InventionTitle>
  <SequenceTotalQuantity>11</SequenceTotalQuantity>
  <SequenceData sequenceIDNumber="1">
    <INSDSeq>
      <INSDSeq_length>133</INSDSeq_length>
      <INSDSeq_moltype>DNA</INSDSeq_moltype>
      <INSDSeq_division>PAT</INSDSeq_division>
      <INSDSeq_feature-table>
        <INSDFeature>
          <INSDFeature_key>source</INSDFeature_key>
          <INSDFeature_location>1..133</INSDFeature_location>
          <INSDFeature_qual>
            <INSDQualifier>
              <INSDQualifier_name>organism</INSDQualifier_name>
              <INSDQualifier_value>Homo sapiens</INSDQualifier_value>
            </INSDQualifier>
            <INSDQualifier>
              <INSDQualifier_name>mol_type</INSDQualifier_name>
              <INSDQualifier_value>genomic DNA</INSDQualifier_value>
            </INSDQualifier>
          </INSDFeature_qual>
        </INSDFeature>
      </INSDSeq_feature-table>
      <INSDSeq_sequence>
atgaaattaaacataaaaarggatgataaaatgagatttgatataaaaaagggttttagagtttagcagagaaggattttgaga
cggcatggagagagacaagggcattaataaaggataaacatattgacaata</INSDSeq_sequence>
      </INSDSeq>
    </SequenceData>
    <SequenceData sequenceIDNumber="2">
      <INSDSeq>
        <INSDSeq_length>29</INSDSeq_length>
        <INSDSeq_moltype>AA</INSDSeq_moltype>
        <INSDSeq_division>PAT</INSDSeq_division>
        <INSDSeq_feature-table>
```

```
<INSDFeature>
  <INSDFeature_key>SOURCE</INSDFeature_key>
  <INSDFeature_location>1..29</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>ORGANISM</INSDQualifier_name>
      <INSDQualifier_value>synthetic construct</INSDQualifier_value>
    </INSDQualifier>
    <INSDQualifier>
      <INSDQualifier_name>MOL_TYPE</INSDQualifier_name>
      <INSDQualifier_value>protein</INSDQualifier_value>
    </INSDQualifier>
    <INSDQualifier>
      <INSDQualifier_name>NOTE</INSDQualifier_name>
      <INSDQualifier_value>Synthetic peptide antigen fragment
      </INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
</INSDSeq_feature-table>
<INSDSeq_sequence>GSLSDVRKDVEKRIDKALEAFKNKMDKEK</INSDSeq_sequence>
</INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="3">
  <INSDSeq>
    <INSDSeq_length>62</INSDSeq_length>
    <INSDSeq_moltype>DNA</INSDSeq_moltype>
    <INSDSeq_division>PAT</INSDSeq_division>
    <INSDSeq_feature-table>
      <INSDFeature>
        <INSDFeature_key>source</INSDFeature_key>
        <INSDFeature_location>1..62</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>organism</INSDQualifier_name>
            <INSDQualifier_value>Homo sapiens</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>mol_type</INSDQualifier_name>
            <INSDQualifier_value>genomic DNA</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
      <INSDFeature>
        <INSDFeature_key>CDS</INSDFeature_key>
        <INSDFeature_location>3..62</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>translation</INSDQualifier_name>
            <INSDQualifier_value>MLAPDCPFDPTRIYSSSLC</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>protein_id</INSDQualifier_name>
            <INSDQualifier_value>4</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
    </INSDSeq_feature-table>
    <INSDSeq_sequence>tgatgctcgcacctgactgtcccttcgacccacacgcatttatagctccagcctgtgctag
    </INSDSeq_sequence>
  </INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="4">
  <INSDSeq>
    <INSDSeq_length>19</INSDSeq_length>
    <INSDSeq_moltype>AA</INSDSeq_moltype>
    <INSDSeq_division>PAT</INSDSeq_division>
```

```
<INSDSeq_feature-table>
  <INSDFeature>
    <INSDFeature_key>SOURCE</INSDFeature_key>
    <INSDFeature_location>1..19</INSDFeature_location>
    <INSDFeature_qual>
      <INSDQualifier>
        <INSDQualifier_name>ORGANISM</INSDQualifier_name>
        <INSDQualifier_value>Homo sapiens</INSDQualifier_value>
      </INSDQualifier>
      <INSDQualifier>
        <INSDQualifier_name>MOL_TYPE</INSDQualifier_name>
        <INSDQualifier_value>protein</INSDQualifier_value>
      </INSDQualifier>
    </INSDFeature_qual>
  </INSDFeature>
</INSDSeq_feature-table>
<INSDSeq_sequence>MLAPDCPFDPTRIYSSSLC</INSDSeq_sequence>
</INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="5">
  <INSDSeq>
    <INSDSeq_length>133</INSDSeq_length>
    <INSDSeq_moltype>DNA</INSDSeq_moltype>
    <INSDSeq_division>PAT</INSDSeq_division>
    <INSDSeq_feature-table>
      <INSDFeature>
        <INSDFeature_key>source</INSDFeature_key>
        <INSDFeature_location>1..133</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>organism</INSDQualifier_name>
            <INSDQualifier_value>Solanum lycopersicum</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>mol_type</INSDQualifier_name>
            <INSDQualifier_value>genomic DNA</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>note</INSDQualifier_name>
            <INSDQualifier_value>common name: tomato</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
      <INSDFeature>
        <INSDFeature_key>modified_base</INSDFeature_key>
        <INSDFeature_location>15</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>mod_base</INSDQualifier_name>
            <INSDQualifier_value>i</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
      <INSDFeature>
        <INSDFeature_key>modified_base</INSDFeature_key>
        <INSDFeature_location>22</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>mod_base</INSDQualifier_name>
            <INSDQualifier_value>OTHER</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>note</INSDQualifier_name>
            <INSDQualifier_value>xanthine</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
    </INSDSeq_feature-table>
  </INSDSeq>
</SequenceData>
```

```
<INSDFeature>
  <INSDFeature_key>variation</INSDFeature_key>
  <INSDFeature_location>60</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>replace</INSDQualifier_name>
      <INSDQualifier_value>c</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
</INSDSeq_feature-table>
<INSDSeq_sequence>
  atgaaattaaaacanaaaaggnatgataaaatgagatttgatataaaaaagggttttagagttagcagagaaggattttgaga
  cggcatggagagagacaagggcattaataaaggataaacatattgacaata</INSDSeq_sequence>
</INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="6">
  <INSDSeq>
    <INSDSeq_length>29</INSDSeq_length>
    <INSDSeq_moltype>AA</INSDSeq_moltype>
    <INSDSeq_division>PAT</INSDSeq_division>
    <INSDSeq_feature-table>
      <INSDFeature>
        <INSDFeature_key>SOURCE</INSDFeature_key>
        <INSDFeature_location>1..29</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>ORGANISM</INSDQualifier_name>
            <INSDQualifier_value>synthetic construct</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>MOL_TYPE</INSDQualifier_name>
            <INSDQualifier_value>protein</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>NOTE</INSDQualifier_name>
            <INSDQualifier_value>Synthetic peptide antigen fragment
            </INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
      <INSDFeature>
        <INSDFeature_key>MOD_RES</INSDFeature_key>
        <INSDFeature_location>3</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>NOTE</INSDQualifier_name>
            <INSDQualifier_value>N-acetylalanine</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
      <INSDFeature>
        <INSDFeature_key>SITE</INSDFeature_key>
        <INSDFeature_location>7</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>NOTE</INSDQualifier_name>
            <INSDQualifier_value>Orn</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
      <INSDFeature>
        <INSDFeature_key>SITE</INSDFeature_key>
        <INSDFeature_location>13</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>NOTE</INSDQualifier_name>
```

```

        <INSDQualifier_value>D-Arginine</INSDQualifier_value>
      </INSDQualifier>
    </INSDFeature_qual>
  </INSDFeature>
  <INSDFeature>
    <INSDFeature_key>UNSURE</INSDFeature_key>
    <INSDFeature_location>15</INSDFeature_location>
    <INSDFeature_qual>
      <INSDQualifier>
        <INSDQualifier_name>NOTE</INSDQualifier_name>
        <INSDQualifier_value>A or V</INSDQualifier_value>
      </INSDQualifier>
    </INSDFeature_qual>
  </INSDFeature>
  <INSDFeature>
    <INSDFeature_key>VARIANT</INSDFeature_key>
    <INSDFeature_location>20</INSDFeature_location>
    <INSDFeature_qual>
      <INSDQualifier>
        <INSDQualifier_name>NOTE</INSDQualifier_name>
        <INSDQualifier_value>I, A, F, Y, alle, MeIle, or Nle
      </INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
<INSDFeature>
  <INSDFeature_key>SITE</INSDFeature_key>
  <INSDFeature_location>22</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>NOTE</INSDQualifier_name>
      <INSDQualifier_value>Homoserine</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
</INSDSeq_feature-table>
<INSDSeq_sequence>GSASDVXKDVKEKRIXKALEXFSNKMDKSK</INSDSeq_sequence>
</INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="7">
  <INSDSeq>
    <INSDSeq_length/>
    <INSDSeq_moltype/>
    <INSDSeq_division/>
    <INSDSeq_sequence>000</INSDSeq_sequence>
  </INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="8">
  <INSDSeq>
    <INSDSeq_length>74</INSDSeq_length>
    <INSDSeq_moltype>RNA</INSDSeq_moltype>
    <INSDSeq_division>PAT</INSDSeq_division>
    <INSDSeq_feature-table>
      <INSDFeature>
        <INSDFeature_key>source</INSDFeature_key>
        <INSDFeature_location>1..74</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>organism</INSDQualifier_name>
            <INSDQualifier_value>Dengue virus 2</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>mol_type</INSDQualifier_name>
            <INSDQualifier_value>genomic RNA</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>

```



```
</INSDSeq_feature-table>
<INSDSeq_sequence>
atgaaattaaaacataaaagggatgataaaatgagatttgatataaaaaaggttttagagtttagcagagaagga
</INSDSeq_sequence>
</INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="9">
  <INSDSeq>
    <INSDSeq_length>120</INSDSeq_length>
    <INSDSeq_moltype>DNA</INSDSeq_moltype>
    <INSDSeq_division>PAT</INSDSeq_division>
    <INSDSeq_feature-table>
      <INSDFeature>
        <INSDFeature_key>source</INSDFeature_key>
        <INSDFeature_location>1..120</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>organism</INSDQualifier_name>
            <INSDQualifier_value>synthetic construct</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>mol_type</INSDQualifier_name>
            <INSDQualifier_value>other DNA</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
      <INSDFeature>
        <INSDFeature_key>misc_feature</INSDFeature_key>
        <INSDFeature_location>1..60</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>note</INSDQualifier_name>
            <INSDQualifier_value>DNA fragment</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
      <INSDFeature>
        <INSDFeature_key>misc_feature</INSDFeature_key>
        <INSDFeature_location>61..120</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>note</INSDQualifier_name>
            <INSDQualifier_value>RNA fragment</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
    </INSDSeq_feature-table>
    <INSDSeq_sequence>
cgacccacgcgtccgaggaaccaaccatcacgtttgaggacttcgtgaaggaattggataataaccgcctccctaccaaattgg
cgagcgccgactcattgtcctcgtaccgtcgagcggc</INSDSeq_sequence>
  </INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="10">
  <INSDSeq>
    <INSDSeq_length>288</INSDSeq_length>
    <INSDSeq_moltype>DNA</INSDSeq_moltype>
    <INSDSeq_division>PAT</INSDSeq_division>
    <INSDSeq_feature-table>
      <INSDFeature>
        <INSDFeature_key>source</INSDFeature_key>
        <INSDFeature_location>1..288</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>organism</INSDQualifier_name>
            <INSDQualifier_value>Candida albicans</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>

```

```
<INSDQualifier_name>mol_type</INSDQualifier_name>
<INSDQualifier_value>genomic DNA</INSDQualifier_value>
</INSDQualifier>
</INSDFeature_qual>
</INSDFeature>
<INSDFeature>
  <INSDFeature_key>CDS</INSDFeature_key>
  <INSDFeature_location>1..288</INSDFeature_location>
  <INSDFeature_qual>
    <INSDQualifier>
      <INSDQualifier_name>translation</INSDQualifier_name>
      <INSDQualifier_value>
        MNLTLHNVIQTDSRGEKFMKIPEIYIRGIHIKYLRIIPDDIMGYAKEQSMINMENNRNRYQKRRGTSS
        GGGGGGGGGSGDSRRFNNRQSHGHNYGRR</INSDQualifier_value>
    </INSDQualifier>
    <INSDQualifier>
      <INSDQualifier_name>transl_table</INSDQualifier_name>
      <INSDQualifier_value>12</INSDQualifier_value>
    </INSDQualifier>
    <INSDQualifier>
      <INSDQualifier_name>protein_id</INSDQualifier_name>
      <INSDQualifier_value>11</INSDQualifier_value>
    </INSDQualifier>
  </INSDFeature_qual>
</INSDFeature>
</INSDSeq_feature-table>
<INSDSeq_sequence>
  atgaatttaaccttacataatgttatacaaaccgattcccgagggtgagaaatttatgaaattcccgaaatatattcgtg
  gtatacatattaaatatttaagaattcctgatgatattatgggatatgcaaagaacaaagtatgataaatatggaaaatag
  aaatcgataccaaaaaagaagaggtactagcagtggtggtggtggtggtggtggtggaagtggtgattcaagaaggtt
  aataatagacaactgcattggacataattatggacgtagatga</INSDSeq_sequence>
</INSDSeq>
</SequenceData>
<SequenceData sequenceIDNumber="11">
  <INSDSeq>
    <INSDSeq_length>95</INSDSeq_length>
    <INSDSeq_moltype>AA</INSDSeq_moltype>
    <INSDSeq_division>PAT</INSDSeq_division>
    <INSDSeq_feature-table>
      <INSDFeature>
        <INSDFeature_key>SOURCE</INSDFeature_key>
        <INSDFeature_location>1..95</INSDFeature_location>
        <INSDFeature_qual>
          <INSDQualifier>
            <INSDQualifier_name>ORGANISM</INSDQualifier_name>
            <INSDQualifier_value>Candida albicans</INSDQualifier_value>
          </INSDQualifier>
          <INSDQualifier>
            <INSDQualifier_name>MOL_TYPE</INSDQualifier_name>
            <INSDQualifier_value>protein</INSDQualifier_value>
          </INSDQualifier>
        </INSDFeature_qual>
      </INSDFeature>
    </INSDSeq_feature-table>
    <INSDSeq_sequence>
      MNLTLHNVIQTDSRGEKFMKIPEIYIRGIHIKYLRIIPDDIMGYAKEQSMINMENNRNRYQKRRGTSSGGGGGGGGSGDSRRF
      NNRQSHGHNYGRR</INSDSeq_sequence>
    </INSDSeq>
  </SequenceData>
</ST26SequenceListing>
```

[Annex IV to ST.26 follows]

ST.26 - ANNEX IV

CHARACTER SUBSET FROM THE UNICODE BASIC LATIN CODE TABLE

Final Draft

Proposal presented by the SEQL Task Force for consideration and adoption at the CWS/4

The ampersand character (0026) is only permitted as part of a predefined entity or as part of a numeric character reference (&#nnnn;). The quotation mark (0022), the apostrophe (0027), the less-than sign (003C), and the greater-than sign (003E) are not permitted and must be represented by their predefined entities.

Unicode code point	Character	Name
0020		SPACE
0021	!	EXCLAMATION MARK
0023	#	NUMBER SIGN
0024	\$	DOLLAR SIGN
0025	%	PERCENT SIGN
0026	&	AMPERSAND
0028	(LEFT PARENTHESIS
0029)	RIGHT PARENTHESIS
002A	*	ASTERISK
002B	+	PLUS SIGN
002C	,	COMMA
002D	-	HYPHEN-MINUS
002E	.	FULL STOP
002F	/	SOLIDUS
0030	0	DIGIT ZERO
0031	1	DIGIT ONE
0032	2	DIGIT TWO
0033	3	DIGIT THREE
0034	4	DIGIT FOUR
0035	5	DIGIT FIVE
0036	6	DIGIT SIX
0037	7	DIGIT SEVEN
0038	8	DIGIT EIGHT
0039	9	DIGIT NINE
003A	:	COLON
003B	;	SEMICOLON
003D	=	EQUALS SIGN
003F	?	QUESTION MARK
0040	@	COMMERCIAL AT
0041	A	LATIN CAPITAL LETTER A
0042	B	LATIN CAPITAL LETTER B
0043	C	LATIN CAPITAL LETTER C
0044	D	LATIN CAPITAL LETTER D
0045	E	LATIN CAPITAL LETTER E
0046	F	LATIN CAPITAL LETTER F
0047	G	LATIN CAPITAL LETTER G
0048	H	LATIN CAPITAL LETTER H
0049	I	LATIN CAPITAL LETTER I
004A	J	LATIN CAPITAL LETTER J
004B	K	LATIN CAPITAL LETTER K
004C	L	LATIN CAPITAL LETTER L
004D	M	LATIN CAPITAL LETTER M
004E	N	LATIN CAPITAL LETTER N
004F	O	LATIN CAPITAL LETTER O
0050	P	LATIN CAPITAL LETTER P
0051	Q	LATIN CAPITAL LETTER Q
0052	R	LATIN CAPITAL LETTER R
0053	S	LATIN CAPITAL LETTER S
0054	T	LATIN CAPITAL LETTER T
0055	U	LATIN CAPITAL LETTER U

Unicode code point	Character	Name
0056	V	LATIN CAPITAL LETTER V
0057	W	LATIN CAPITAL LETTER W
0058	X	LATIN CAPITAL LETTER X
0059	Y	LATIN CAPITAL LETTER Y
005A	Z	LATIN CAPITAL LETTER Z
005B	[LEFT SQUARE BRACKET
005C	\	REVERSE SOLIDUS
005D]	RIGHT SQUARE BRACKET
005E	^	CIRCUMFLEX ACCENT
005F	_	LOW LINE
0060	`	GRAVE ACCENT
0061	a	LATIN SMALL LETTER A
0062	b	LATIN SMALL LETTER B
0063	c	LATIN SMALL LETTER C
0064	d	LATIN SMALL LETTER D
0065	e	LATIN SMALL LETTER E
0066	f	LATIN SMALL LETTER F
0067	g	LATIN SMALL LETTER G
0068	h	LATIN SMALL LETTER H
0069	i	LATIN SMALL LETTER I
006A	j	LATIN SMALL LETTER J
006B	k	LATIN SMALL LETTER K
006C	l	LATIN SMALL LETTER L
006D	m	LATIN SMALL LETTER M
006E	n	LATIN SMALL LETTER N
006F	o	LATIN SMALL LETTER O
0070	p	LATIN SMALL LETTER P
0071	q	LATIN SMALL LETTER Q
0072	r	LATIN SMALL LETTER R
0073	s	LATIN SMALL LETTER S
0074	t	LATIN SMALL LETTER T
0075	u	LATIN SMALL LETTER U
0076	v	LATIN SMALL LETTER V
0077	w	LATIN SMALL LETTER W
0078	x	LATIN SMALL LETTER X
0079	y	LATIN SMALL LETTER Y
007A	z	LATIN SMALL LETTER Z
007B	{	LEFT CURLY BRACKET
007C		VERTICAL LINE
007D	}	RIGHT CURLY BRACKET
007E	~	TILDE

[Annex V to ST.26 follows]

ST.26 - ANNEX V

ADDITIONAL DATA EXCHANGE REQUIREMENTS (FOR PATENT OFFICES ONLY)

Final Draft

Proposal presented by the SEQL Task Force for consideration and adoption at the CWS/4

In the context of data exchange with database providers (INSD members), the Patent Offices should populate for each sequence the element `INSDSeq_other-seqids` with one `INSDSeqid` containing a reference to the corresponding published patent and the sequence identification number in the following format:

`pat|{office code}|{publication number}|{document kind code}|{sequence identification number}`

where office code is the code of the IP office publishing the patent document as set forth in ST.3; document kind code is the code for the identification of different kinds of patent documents as set forth in ST.16; publication number is the publication number of the application or patent; and Sequence identification number is the number of the sequence in that application or patent.

Example:

`pat|WO|2013999999|A1|123456`

Which would be translated into a valid XML instance as:

```
<INSDSeq_other-seqids>
  < INSDSeqid>pat | WO | 2013999999 | A1 | 123456</INSDSeqid>
</INSDSeq_other-seqids>
```

Where "123456" is the 123456th sequence from the WO publication no. 2013999999 (A1).

[End of Annex II and of document]