

PROBLEMAS LINGUISTICOS EN LA AUTOMATIZACION DE LOS SISTEMAS DE CLASIFICACION DOCUMENTAL

Moya, F.; Hípola, P. «Problemas lingüísticos en la automatización de los sistemas de clasificación documental». Procesamiento del Lenguaje Natural, octubre 1987, 5, págs. 73-85.

Los sistemas de clasificación de documentos más utilizados en bibliotecas y centros de documentación científicos a veces resultan poco operativos para usuarios poco familiarizados con ellos y a menudo se convierten más en un obstáculo que en una ayuda para la recuperación de información. Esta situación suele producirse especialmente con los lenguajes de clasificación enciclopédicos que se basan en las denominadas clasificaciones decimales. En este trabajo describe un sistema que está preparando los autores concebido para actuar como interfaz entre notaciones codificadas en CDU y el usuario. Los procesos de codificación y decodificación automáticas han de superar los problemas usuales en cualquier programa interpretante de lenguaje natural.

La clasificación de documentos que se realiza en centros de documentación y bibliotecas suele basarse en el uso de "lenguajes documentales", es decir, según la clásica definición de Courrier (1976), ciertos tipos de lenguajes artificiales que permiten elaborar la representación formalizada de documentos y preguntas documentales que interesan a un grupo de usuarios, a fin de permitir recuperar los documentos que correspondan a las búsquedas.

El afán por elaborar lenguajes documentales con alto grado de condensación y formalización ha producido que en algunos casos las indizaciones que se realizan sean sólo fácilmente decifrables por personal especializado. Esta es la situación que de hecho se suele producir en los centros en los que un usuario sin preparación especial debe enfrentarse con referencias indizadas por medio de la llamada Clasificación Decimal Universal (CDU).

Muy frecuentemente se han formulado críticas a la CDU, pero en la práctica su uso está fuertemente arraigado en Europa. Un comité, de la Federación Internacional de Documentación (FID) se encarga del mantenimiento de la clasificación desde que se editó por primera vez a principios de siglo. Sin embargo, a pesar de que el sistema se utiliza en numerosos centros desde hace más de ochenta años, las indizaciones que se llevan a cabo con la CDU continúan siendo para un gran sector del público una retahíla

ininteligible de dígitos y signos de puntuación.

Una solución apropiada para paliar este problema sería poder contar con un sistema informático que actúe como interface entre las notaciones codificadas en CDU y el lenguaje natural del usuario. El sistema deberá actuar por los menos como interpretador en la decodificación de las notaciones. Pero, si pudiera contar con mecanismos propios de autoaprendizaje, podría servir también para realizar codificaciones CDU a partir de informaciones suministradas en términos de lenguaje natural.

En las siguientes páginas se describen algunas características del proyecto encaminado a diseñar un sistema de este tipo, en cuya preparación están trabajando los autores.

La Clasificación Decimal Universal es un sistema de indexación documental por temas (subject indexing), ya que los puntos de acceso que sirven para la recuperación de información son las principales ideas que el indexador ha localizado en los documentos; de carácter enciclopédico, pues está concebida para representar cualquier materia de conocimiento, no se limita a un dominio específico; de estructura precoordinada, debido a que los diferentes aspectos que componen un tema se encuentran ya coordinados antes de que se realice la indexación (si bien es verdad que existen procedimientos que permiten poscoordinar descriptores tanto en el proceso de indexación de documentos como en la búsqueda documental); y de vocabulario controlado, porque, previamente a la anotación documental, se ha establecido un listado de todos los descriptores que se pueden emplear.

Las rutinas que efectúan la decodificación automática de las notaciones se ocupan en un primer momento de gestionar una base de datos, compuesta por todas las notaciones que incluye la edición abreviada castellana de la CDU, junto a sus correspondientes expresiones, y que, desde el punto de vista semántico, está organizada en forma de árbol, pues la estructura jerárquica de la clasificación consta de diez divisiones principales, cada una de las cuales posee sucesivas subdivisiones a las que les corresponde una notación numérica de acuerdo con el sistema decimal. Las cifras de las notaciones se agrupan en cadenas de tres dígitos separadas por un punto.

```
\ar110,sa20
\font3\3\tab40\font6\Ciencias sociales
\font3\33\tab40\font6\Economía
\font3\337\tab40\font6\Política aduanera
\font3\337.9\tab40\font6\Sistemas aduaneros
\font3\337.91\tab40\font6\Tratados de comercio (...)

\font3\337.912\tab40\font6\Reciprocidad
\font2,ar60,sa0
```

Presentada una notación al sistema, éste localiza cuál es la expresión que la CDU tiene asignada a esa cadena numérica y entrega al usuario dicha expresión en términos de lenguaje natural. El procedimiento es sumamente sencillo cuando se trata de notaciones que se refieren a un conjunto de conceptos previamente establecidos en la clasificación. Todas las cadenas numéricas simples -incluidas las subdivisiones que genera el símbolo "subdividirse" y excluidas las subdivisiones analíticas

introducidas por "punto cero" (@.0@), a las que nos referiremos m s adelante- se incluyen en la base de datos de forma que el acceso es inmediato. Analizada la notaci>n que se presenta al sistema, un primer paso es confirmar si la cadena num,rica se encuentra, tal cual, como campo clave de alguno de los registros de la base.

Para poner a punto la base de datos est siendo necesario en muchas ocasiones modificar la redacci>n de las expresiones que presenta la edici>n abreviada. Por ejemplo, aunque en esta edici>n se haya redactado:

```
\ar110,sa20
\font3\532\tab40\font6\Me nica de los fluidos. Hidr ulica
\font3\532.14\tab40\font6\Densidad
\font2,ar60,sa0
nosotros, por nuestra parte, para simplificar el proceso
decodificador, de momento preferimos modificar la redacci>n de
expresiones como ,sta, consignando en nuestra base:
\ar110,sa20
\font3\532.14\tab40\font6\Densidad de los fluidos
\font2,ar60,sa0
```

En el futuro se arbitrar la optimizaci>n del sistema, a fin de conseguir que, por medio de instrumentos software -que realicen combinaciones sint cticas elementales en lenguaje natural, o representaciones arbtreas, etc.-, sea posible minimizar el consumo de memoria en la base de datos, eliminando elementos l,xicos redundantes.

La decodificaci>n ha de seguir un proceso m s completo cuando en la notaci>n presentada al sistema no slo se incluye una subdivisi>n de las tablas principales. Entonces pueden encontrarse dos posibilidades distintas:

```
\sa+5
```

1. Si es una indizaci>n referida a un documento que trata sucesivamente de dos o m s temas, aparecer n señalados esos temas por sus notaciones correspondientes, unidas por el s;mbolo de extensi>n o de adici>n.

2. Si se refiere a una "noci>n tem tica compleja" en la que se relacionan dos o m s notaciones, aparecer una cadena num,rica m s elaborada, cuya sintaxis se articula por medio de los s;mbolos de relaci>n, de nexo indisoluble, los corchetes y por medio de los distintos auxiliares.

```
\sa-5
```

Cuando se encuentra el signo de la extensi>n es porque el tema principal del documento est simbolizado por m s de un nfmero de las tablas principales y tales nfmeros se encuentran contiguos en las tablas. Aparecen el primer y ltimo nfmero separados por una barra (@/@). Cabe la posibilidad de que se halle reducido el tamao de la cadena, apareciendo consignados del ltimo nfmero fnicamente los d;gitos que varian con relaci>n al primero, incluido el ltimo punto que es comn a los dos.

```
\ar110,sa20
\font3\546.13\tab40\font6\Quimica del cloro
\font3\546.14\tab40\font6\Quimica del bromo
\font3\546.13/.14\tab40\font6\Quimica del cloro y del bromo
```

\font2,ar60,sa0

El s;mbolo de adici;n (@+@), dotado de una carga significativa equivalente al de extensi;n, ha sido empleado por el indizador siempre que las notaciones que se enumeran no se encuentren contiguas en la tabla sistem tica. En este caso no se hallar nunca abreviaci;n del lltimo nfmero.

\ar110,sa20

\font3\625.31 + 625.35\tab40\font6\Ferrocarriles de v;a estrecha y ferrocarriles de v;a ancha

\font2,ar60,sa0

Como se puede observar, con la adici;n y la extensi;n se verifica una agrupamiento de nociones en cierta forma asimilable a la uni;n que produce el operador OR inclusivo del lgebra de Boole.

La relaci;n, indicada con el colon (@:@), sexala la interacci;n entre las nociones representadas por cada uno de los nfmeros que se han utilizado. En muchas ocasiones el s;mbolo sirve para indicar que estas relaciones son ellas mismas tema principal del documento. Se entiende que la relaci;n es bidireccional. Este s;mbolo resulta un tanto ambiguo, pues no explica la naturaleza de la relaci;n.

\ar110,sa20

\font3\31\tab40\font6\Estad;stica

\font3\324\tab40\font6\Elecciones. Plebiscitos. Referendum

\font3\31:324\tab40\font6\Estad;stica electoral

\font2,ar60,sa0

Si aparece el doble colon (@::@), s;mbolo de nexo indisoluble, es porque el indizador dese; dejar constancia de una relaci;n unidireccional:

\ar110,sa20

\font3\17\tab40\font6\Moral

\font3\7\tab40\font6\Arte

\font3\17::7\tab40\font6\La influencia de la moral en el arte

\font2,ar60,sa0

Esta lltima notaci;n nunca podr ser interpretada como "la influencia del arte en la moral"

Los corchetes (@[]@) ofrecen la posibilidad de establecer ecuaciones l;gicas en cierta forma asimilables a la del lgebra de Boole.

La aparici;n de los denominados "auxiliares" permite identificar clasificaciones "por facetas". Los auxiliares comunes, que pueden encontrarse aplicados a cualquier subdivisi;n de las tablas principales, son los siguientes:

AUXILIAR COMUN	COMIENZA POR
de forma	@(0@ (par,ntesis cero)
de tiempo	@"@ (comillas)
de lugar	@(1@/09@ (par,ntesis...)
de raza y naci;n	@(=@ (par,ntesis igual)
de lengua	@=@ (igual)
de p. de vista	@.00@ (punto cero cero)

Por su parte, los auxiliares especiales se encontrar n

empleados sólo en aquellas partes de la CDU en las que est expresamente autorizado su uso. El apóstrofo (@'@) expresa la síntesis de varios conceptos, cuando de dos o más componentes se crea una noción que tiene su propia individualidad. Se usa, por ejemplo, dentro de la química para referirse a aleaciones. El guion (@-@) introduce elementos, componentes, propiedades y otros detalles de la materia del número principal de la CDU. Las series de punto cero (@.01@/.09@) identifican clases y subclases de diferentes características: actividades, proceso, etc.

Es posible acumular notaciones que incluyan varios símbolos y auxiliares:

```
\ar110,sa20
\font3\368.42.008 (460) "1973" (058)
\font3\368.42\tab40\font6\Seguro de enfermedad
\font3\.008\tab40\font6\En organizaci n
\font3\ (460)\tab40\font6\En Espa a
\font3\"1973"\tab40\font6\En el a o 1973
\font3\ (058)\tab40\font6\Anuario
\font2,ar60,sa0
```

El orden de los ítems que componen una notación compleja de CDU no está previamente determinado, si bien se suele recomendar que se redacten las notaciones comenzando por los conceptos más generales, descendiendo progresivamente hacia lo más específico.

En cualquier caso, por lo visto hasta ahora queda claro que el estricto formalismo de la sintaxis de todos estos símbolos y auxiliares, en combinación con el control y la precoordinación del sistema, garantiza un grado elevado de univocidad semántica, gracias al cual existen pocas posibilidades de que se produzcan en el proceso decodificador interpretaciones polisémicas.

Aprovechando estas características resulta posible organizar el programa interpretador sin que aparezcan excesivos ruidos. La representación arbórea de los conceptos puede generarse con gran facilidad, dada la estructura jerárquica de la CDU. Pero, para ofrecer decodificaciones más "amigables" con el usuario, preferimos asignar a cada posible combinación sintáctica algún sintagma -generalmente de tipo funcional gramatical- o nexo ("y", "en relación con", "durante", "de", etc.) que traduzca en elementos lógicos de lenguaje natural el conjunto finito de conectores sintáctico-semánticos que la CDU conoce.

Por otra parte, el proyecto que se ha concebido pretende partir de la misma base de datos con la que se efectúa la decodificación para desarrollar una aplicación que facilite el proceso interactivo entre usuario y base de datos, a fin de que el sistema pueda generar notaciones CDU utilizando la información lógica que suministre el usuario.

Se ha pensado que la aplicación gire en torno a la gestión de un fichero invertido de formas lógicas y expresiones compuestas, consignadas en términos de lenguaje natural. Cada entrada del fichero contaría al menos con un puntero que señale a su término lexical canónico correspondiente. Los punteros de los lexicales canónicos remitirían a las expresiones contenidas en la base de datos, que a su vez estarían relacionadas con los números propios de la CDU.

En algunos casos, bastar con entregar al sistema una descripción del tema en lenguaje natural. Desechadas las palabras "vacías" de significado y localizados los términos significativos fundamentales, en muchas ocasiones el programa estar preparado para ofrecer de forma inmediata una o varias posibles codificaciones, de manera que el usuario pueda elegir la que, por su caracterización semántica, parezca pertinente. Así, por ejemplo, al intentar codificar un tema como "enfermedades que sufren las abejas", localizada la expresión "enfermedades de los animales" (591.2), dado que para referirse a los distintos animales no existe una subdivisión preceptuada en las tablas, el sistema deberá estar preparado para relacionar esta noción con la que le corresponde a la forma léxica "abeja" (indizable por 595.799): 591.2:595.799.

Si el sistema no soluciona de esta forma el problema, se comenzar un proceso más completo. Dado que el principio básico de la CDU consiste en que se clasifiquen los documentos en primer lugar de acuerdo con las disciplinas a las que pertenecen, hasta conseguir determinar, de la forma más específica posible, el tema principal, en este proceso se deberá, por medio de la interacción con el usuario, a través de preguntas y respuestas, avanzar por las ramas del árbol, hasta llegar al grado de especificidad en la descripción que se desee -y la CDU lo permita-. Esto se hará a través de la identificación de los elementos léxicos que el usuario elija.

Antes de considerar definitiva una expresión -y su correspondiente notación numérica- considerada a juicio del usuario pertinente, el sistema actuar de guía en un rastreo horizontal y vertical por el árbol que constituyen las tablas principales de la CDU para asegurarse de que el concepto identificado se encuentra en el contexto más apropiado de la clasificación y en el grado de especificidad oportuno. Además, la existencia, en muchos lugares de la CDU, de símbolos de reenvío facilita el desarrollo de desplazamientos conceptuales "en red" dentro del árbol de conocimiento CDU, similares a los que son usuales en programas que se encargan de la gestión de thesauros.

Para que todo esto sea posible, se han previsto procedimientos que solventen ciertos problemas frecuentes. En primer lugar, el listado de formas y expresiones léxicas no siempre contendrá todas las palabras que el usuario formule. Por eso, el fichero invertido deberá permanecer abierto siempre, dispuesto a crecer por atribuciones que se desprendan en el proceso de interacción con el usuario. Cada vez que una forma léxica del usuario no se encuentra en el fichero invertido, el sistema, tras las preguntas al usuario, ha de quedar en condiciones de localizar, en primer lugar, formas de significado equivalente -si es posible- y, en segundo lugar, debe incorporar la nueva forma o expresión al fichero y asignarle punteros. De esta manera, si en el fichero inverso no aparece la expresión "viaje de novios", a través de estos procedimientos de "autoaprendizaje" ser posible añadir la expresión al fichero, con unos punteros que remitan a "matrimonio" (392.5) y "viajes" (910).

Así el sistema queda cada vez más enriquecido.

Por otra parte, como paso previo a todos los anteriores, se ha tenido en cuenta que un mismo elemento léxico puede representar un tema principal o cualquier otra de las especificidades temáticas "por facetas". Por ello es necesario prever un cuestionario "por facetas" y así se evitar, por ejemplo, que ante un documento de título "Diccionario de filología" se interpretara que el término "diccionario" forma parte del tema principal, o que "La casa de Bernarda Alba" sea indexada como vivienda unifamiliar.

Los problemas que acompañan constantemente la implementación de un programa de estas características son los que se refieren a la interpretación semántica de los términos del lenguaje natural. Un documento titulado "Las enfermedades de las abejas" podría clasificarse dentro de la medicina o de la biología según si estos animales son los agentes o los pacientes de la enfermedad.