UNIVERSIDAD DE A CORUÑA
Departamento de Computación

Proyecto Fin de Carrera en Ingeniería Informática

Extensiones del Formalismo HMM para la Etiquetación del Lenguaje Natural

Autor:

GLORIA ANDRADE SANCHEZ

Director:

JORGE GRAÑA GIL

Enero de 2002

A mi familia

Dr. Jorge Graña Gil
Profesor Titular de Universidad Interino
Departamento de Computación
Universidad de A Coruña

CERTIFICA:

Que la memoria titulada "*Extensiones del Formalismo HMM para la Etiquetación del Lenguaje Natural*" ha sido realizada por Dña. Gloria Andrade Sánchez bajo mi dirección en el Departamento de Computación de la Universidad de A Coruña, y concluye el Proyecto Fin de Carrera que presenta para optar al título de Ingeniero en Informática.

A Coruña, 24 de enero de 2002

Fdo.: Jorge Graña Gil

Título del Proyecto: Extensiones del Formalismo HMM para la Etiquetación de Textos en Lenguaje Natural

Clase del Proyecto: Investigación y Desarrollo

Autor: Gloria Andrade Sánchez

Director: Jorge Graña Gil

Fecha:

Tribunal

Presidente:

Vocal 1°:

Vocal 2°:

Vocal 3°:

Secretario:

Calificación:

Resumen

Extensiones del Formalismo HMM para la Etiquetación de Textos en Lenguaje Natural

El objetivo último que persigue el Procesamiento del Lenguaje Natural es el perfecto análisis y entendimiento de los lenguajes humanos. Actualmente, estamos todavía lejos de conseguir este objetivo. Por esta razón, la mayoría de los esfuerzos de investigación de la lingüística computacional han sido dirigidos hacia tareas intermedias que dan sentido a alguna de las múltiples características estructurales inherentes a los lenguajes, sin requerir un entendimiento completo. Una de esas tareas es la asignación de categorías gramaticales a cada una de las palabras del texto. Este proceso se denomina también etiquetación.

La eliminación de ambigüedades es una tarea crucial durante el proceso de etiquetación de un texto en lenguaje natural. Si tomamos aisladamente, por ejemplo, la palabra `sobre`, vemos que puede tener varias categorías posibles en español: sustantivo, preposición o verbo. Sin embargo, si examinamos el contexto en el que aparece dicha palabra, seguramente sólo una de ellas es posible. Por otra parte, el interés se centra también en asignar una etiqueta a todas aquellas palabras que aparecen en los textos, pero que no están presentes en nuestro diccionario, y garantizar de alguna manera que ésa es la etiqueta correcta. Un buen rendimiento en esta fase asegura la viabilidad de procesamientos posteriores tales como los análisis sintáctico y semántico.

Tradicionalmente, el problema de la etiquetación se aborda a partir de recursos lingüísticos bajo la forma de diccionarios y textos escritos, previamente etiquetados o no. Esta línea de desarrollo se denomina lingüística basada en corpus. Dichos textos se utilizan para ajustar los parámetros de funcionamiento de los etiquetadores. Este proceso de ajuste se denomina entrenamiento. Las técnicas tradicionales engloban métodos basados en reglas, tales como el aprendizaje de etiquetas mediante transformaciones y dirigido por el error, y también métodos estocásticos, tales como los modelos de Markov ocultos o HMM,s (*Hidden Markov Models*), que constituyen actualmente la aproximación que ofrece mejores rendimientos.

Aún con todo esto, un pequeño porcentaje de palabras etiquetadas erróneamente (2-3%) es una característica que está siempre presente en los sistemas de etiquetación puramente estocásticos. Este proyecto aborda el diseño e implementación de un sistema de etiquetación híbrido que considere la aplicación combinada de reglas contextuales y algoritmos de programación dinámica para intentar eliminar estos errores residuales. Dichas reglas deben ser proporcionadas por un usuario experto, y el sistema se ocupa de compilarlas bajo la forma de una estructura matemática denominada traductor de estado finito, que es la que permite que una ejecución eficiente de las mismas.

Por otra parte, la mayoría de los etiquetadores actuales asumen que los textos aparecen ya correctamente segmentados, es decir, divididos en *tokens* que identifican perfectamente cada componente. Sin embargo, esta hipótesis no es realista debido a la naturaleza heterogénea de los textos. Las mayores dificultades surgen cuando la segmentación es ambigua. Por ejemplo, la expresión `sin embargo` se etiquetará normalmente de manera conjunta como una conjunción, pero en algún otro contexto podría ser una secuencia formada por una preposición

y un sustantivo. De igual forma, la palabra `ténselo` puede ser una forma del verbo `tener` con dos pronombres enclíticos, o bien una forma del verbo `tensar` con un solo pronombre.

Debido a estas segmentaciones ambiguas, un etiquetador debería ser capaz de enfrentarse a flujos de *tokens* de distinta longitud. Es decir, no sólo debería ser capaz de decidir qué etiqueta asignar a cada *token*, sino que además debería saber decidir si algunos de ellos constituyen o no una misma entidad y asignar, en cada caso, la cantidad de etiquetas adecuada en función de las diferentes alternativas de segmentación. Así pues, este proyecto aborda también la fase de diseño de una extensión del algoritmo de Viterbi (el algoritmo de programación dinámica sobre HMM,s que realiza la etiquetación) capaz de etiquetar flujos de *tokens* de distinta longitud con una complejidad temporal comparable a la del algoritmo de clásico.

Palabras Clave: Procesamiento del Lenguaje Natural (*Natural Language Processing*), Lexicografía Computacional (*Computational Lexicography*), Etiquetación de las Partes del Discurso (*Part-of-Speech Tagging*), Modelos de Markov Ocultos (*Hidden Markov Models*), Gramáticas de Restricciones (*Constraint Grammars*), Traductores de Estado Finito (*Finite-State Transducers*).

Agradecimientos

Ha llegado el momento de expresar mi más sincero agradecimiento a todas las personas que me han ayudado a llegar hasta aquí, compartiendo conmigo su sabiduría, su formación, su entusiasmo, su amistad y su confianza durante estos últimos años.

A mi director de proyecto, Jorge Graña, por toda la ayuda y dedicación que me ha prestado durante el desarrollo de este proyecto.

A mis compañeros de laboratorio, con los que he compartido estos últimos meses de trabajo.

A mis compañeros de clase, con los que he vivido muchos momentos.

A Jano, mi compañero de prácticas, con el que he formado un buen equipo de trabajo, y el que me ha aguantado en los momentos de máxima tensión.

A mis padres, que me han dado la oportunidad de recibir una buena educación y siempre me han apoyado en mis decisiones.

A mi hermano, que siempre ha estado ahí cuando lo necesitaba.

A mis amigos y amigas, por las dosis de distracción que uno siempre necesita.

Y a Suso, por haber confiado siempre en mis posibilidades.

A todos y por todo, muchísimas gracias.

Índice General

Resumen **ix**

Agradecimientos **xi**

I Etiquetación del lenguaje natural: conceptos previos **1**

1 Introducción **3**
1.1 Fuentes de información relevantes para la etiquetación 4
1.2 Los primeros etiquetadores 6
1.3 Rendimiento y precisión de los etiquetadores 7
1.4 Aplicaciones de la etiquetación 8
1.5 Etiquetación mediante gramáticas de restricciones 9
1.6 Motivación y objetivos del proyecto 10
1.7 Estructura de la presente memoria 12

2 Análisis léxico de grandes diccionarios **15**
2.1 Modelización de un diccionario 15
2.2 Autómatas finitos acíclicos deterministas numerados 20
2.2.1 Construcción del autómata 21
2.2.2 El algoritmo de minimización de la altura 25
2.2.3 Asignación y uso de los números de indexación 29
2.2.4 Algoritmos de construcción incrementales 32
2.3 Otros métodos de análisis léxico 35

II Sistemas de etiquetación tradicionales **39**

3 Modelos de Markov ocultos (HMM,s) **41**
3.1 Procesos de Markov de tiempo discreto 42
3.2 Extensión a modelos de Markov ocultos 44
3.3 Elementos de un modelo de Markov oculto 45
3.4 Las tres preguntas fundamentales al usar un HMM 46
3.4.1 Cálculo de la probabilidad de una observación 47
3.4.1.1 Procedimiento hacia adelante 48
3.4.1.2 Procedimiento hacia atrás 49
3.4.2 Elección de la secuencia de estados más probable 50
3.4.2.1 Algoritmo de Viterbi 51
3.4.2.2 Implementaciones alternativas del algoritmo de Viterbi 56
3.4.3 Estimación de los parámetros del modelo 57

3.4.3.1 Estimación no supervisada: algoritmo de Baum-Welch 57
3.4.3.2 Estimación supervisada: métodos de suavización 62
3.4.3.3 Estimación combinada mediante métodos híbridos 69
3.4.3.4 Integración de diccionarios 70
3.4.3.5 Tratamiento de palabras desconocidas 71
3.5 Variantes de implementación de los HMM,s 74
3.6 Otras aplicaciones de los HMM,s 75

4 Aprendizaje de etiquetas basado en transformaciones 77
4.1 Arquitectura interna del etiquetador de Brill 77
4.1.1 El etiquetador léxico 78
4.1.2 El etiquetador de palabras desconocidas 78
4.1.3 El etiquetador contextual 80
4.2 Aprendizaje basado en transformaciones y dirigido por el error 83
4.3 Complejidad del etiquetador de Brill 84
4.4 Relación con otros modelos de etiquetación 85
4.4.1 Árboles de decisión 86
4.4.2 Modelos probabilísticos en general 86

III Reglas contextuales y traductores de estado finito 89

5 Etiquetación utilizando reglas contextuales 91
5.1 Definición del lenguaje de reglas 93
5.1.1 LEMMERS: Lenguaje de Etiquetado MEdiante Restricciones Simples. . . 94
5.2 Mejoras del formalismo de reglas del lenguaje LEMMERS 97
5.2.1 Esquemas de reglas 100

6 Compilación de reglas contextuales utilizando traductores de estado finito 103
6.1 Definición formal de un traductor de estado finito 104
6.2 Construcción de un traductor a partir de reglas contextuales 105
6.2.1 Formatos de E/S con los que trabaja el traductor de estado finito 106
6.2.2 Construcción de los traductores de estado finito 108
6.3 Modo de operación de los traductores de estado finito 120
6.3.1 Creación de los traductores de estado finito 121
6.3.2 Compilación de los traductores de estado finito 124
6.3.3 Funcionamiento de los traductores de estado finito 125
6.4 Trabajo de los *FST*s a bajo nivel 128
6.5 Un ejemplo completo 129

IV Formalización del proceso de segmentación 139

7 Extensiones del algoritmo de Viterbi 141
7.1 El nuevo etiquetador 143
7.2 Extensiones del algoritmo de Viterbi 145
7.2.1 Representación de las alternativas de segmentación sobre un *retículo* . . . 145
7.2.2 Funcionamiento del algoritmo de Viterbi sobre un *retículo* 147
7.2.3 Etiquetación y segmentación combinada sobre el algoritmo de Viterbi . . 150
7.3 Cálculo de la complejidad 151

8 Conclusiones y trabajo futuro **157**

V Apéndices y bibliografía **161**

A Juegos de etiquetas **163**
A.1 Etiquetas Galena 163
A.2 Etiquetas Corga 164

Bibliografía **165**

Parte I

Etiquetación del lenguaje natural: conceptos previos

Capítulo 1

Introducción

El objetivo último que persigue el Procesamiento del Lenguaje Natural o NLP[1] es el perfecto análisis y entendimiento de los lenguajes humanos. Su utilidad es obvia, ya que consiguiendo esto dispondríamos, por ejemplo, de interfaces amigables hombre-máquina utilizando lenguaje natural, de buenos sistemas de búsqueda de información, de traductores, etc. Actualmente, estamos todavía lejos de conseguir este objetivo. Por esta razón, la mayoría de los esfuerzos de investigación en lo que al NLP se refiere han sido dirigidos hacia tareas intermedias que dan sentido a alguna de las múltiples características estructurales inherentes a los lenguajes, sin requerir un entendimiento completo. Una de esas tareas es la asignación de categorías gramaticales a cada una de las palabras del texto. Este proceso se denomina también *etiquetación* de las partes del discurso o POST[2]. En definitiva, se trata de decidir si cada palabra es un sustantivo, un adjetivo, un verbo, etc. Por ejemplo, si consideramos aisladamente la palabra `sobre`, vemos que puede ser:

- Un sustantivo, como por ejemplo en la frase: `mételo en ese sobre`.
- Una preposición, como por ejemplo en la frase: `déjalo sobre la mesa`.
- O un verbo en primera o tercera persona del presente de subjuntivo del verbo `sobrar`, como por ejemplo en la frase: `dame lo que te sobre`.

Es decir, si echamos un vistazo al contexto en el que dicha palabra aparece, es muy probable que sólo una de esas tres etiquetas sea la correcta. El proceso de etiquetación debe eliminar por tanto este tipo de ambigüedades y encontrar cuál es el papel más probable que juega cada palabra dentro de una frase. Es más, dicho proceso debe ser capaz también de asignar una etiqueta a cada una de las palabras que aparecen en un texto y que no están presentes en nuestro diccionario, y garantizar de alguna manera que ésa es la etiqueta correcta.

Como ya hemos visto, la etiquetación es un problema de ámbito limitado. En lugar de construir un análisis completo, simplemente se establecen las categorías de las palabras, y se dejan de lado problemas tales como por ejemplo el de encontrar la correcta ligadura de las frases preposicionales. Debido a esto, la etiquetación es más sencilla de resolver que los análisis sintáctico o semántico, y el rendimiento es bastante elevado. Las aproximaciones más exitosas son capaces de etiquetar correctamente alrededor del 95-97% de las palabras. Sin embargo, es

[1] A lo largo de la presente memoria intentaremos hacer referencia a todos los conceptos propios del lenguaje especializado de la materia a tratar con su correspondiente término en español; no obstante, la mayoría de los acrónimos utilizados constituirán una excepción a este principio, ya que muchas veces su traducción resulta excesivamente artificial; en este caso, utilizaremos la sigla NLP, que responde al término inglés *Natural Language Processing*.

[2] *Part-Of-Speech Tagging*.

importante señalar que estas cifras tan impactantes no son tan buenas como parecen, ya que normalmente son el resultado de una evaluación palabra por palabra. Por ejemplo, en muchos géneros de escritura tales como los artículos periodísticos, donde el número medio de palabras por frase puede ser de unas veinte o veinticinco, un rendimiento del 95% todavía implica que pueden aparecer entre una y dos palabras mal etiquetadas en cada frase. Además, estos errores no siempre se localizan en las categorías más pobladas, tales como sustantivos, adjetivos o verbos, donde en principio parece más probable el encontrarse con palabras desconocidas. Muchas veces, los errores aparecen asociados a las partículas que conectan los sintagmas entre sí, tales como preposiciones, conjunciones o relativos, y pueden hacer que una frase tome un significado muy distinto del original.

Aún con todo esto, y a pesar de sus limitaciones, la información que se obtiene mediante la etiquetación es muy útil. Las potenciales aplicaciones de los textos en lenguaje natural aumentan cuando dichos textos están anotados, y el primer nivel lógico de anotación es normalmente la asignación de este tipo de etiquetas gramaticales a cada una de las palabras. Por tanto, los textos ya no serán vistos como una mera secuencia de caracteres, sino como una secuencia de entidades lingüísticas con algún tipo de significado natural. El texto etiquetado puede utilizarse entonces para introducir nuevos tipos de anotaciones, normalmente mediante posteriores análisis sintácticos o semánticos, o puede utilizarse también para recoger datos estadísticos sobre el uso de un idioma que pueden servir para múltiples aplicaciones. El trabajo a partir de las palabras etiquetadas hace mucho más viables tareas tales como el proceso y síntesis del diálogo, la lexicografía computacional, o el más reciente y novedoso tema de la recuperación de información.

1.1 Fuentes de información relevantes para la etiquetación

Para decidir cuál es la etiqueta correcta de una palabra existen básicamente dos fuentes de información:

1. La primera de ellas consiste en mirar las etiquetas de las otras palabras que pertenecen al contexto en el que aparece la que nos interesa. Esas palabras podrían ser también ambiguas, pero el hecho de observar secuencias de varias etiquetas nos puede dar una idea de cuáles son comunes y cuáles no lo son. Por ejemplo, en inglés, una secuencia como artículo-adjetivo-sustantivo es muy común, mientras que otras secuencias como artículo-adjetivo-verbo resultan muy poco frecuentes o prácticamente imposibles. Por tanto, si hubiera que elegir entre sustantivo o verbo para etiquetar la palabra `play` en la frase `a new play`, obviamente optaríamos por la primera de las etiquetas.

   Este tipo de estructuras constituyen la fuente de información más directa para el proceso de etiquetación, pero por sí misma no resulta demasiado exitosa: uno de los primeros etiquetadores basado en reglas deterministas que utilizaba este tipo de patrones sintagmáticos etiquetaba correctamente sólo el 77% de las palabras [Greene y Rubin 1971]. Una de las razones de este rendimiento tan bajo es que en inglés las palabras que pueden tener varias etiquetas son efectivamente muy numerosas, debido sobre todo a procesos productivos como el que permite a casi todos los sustantivos que podamos tener en nuestro diccionario transformarse y funcionar como verbos, con la consiguiente pérdida de la información restrictiva que es necesaria para el proceso de etiquetación.

2. Sin embargo, existen palabras que, aunque puedan ser usadas como verbos, su aparición es mucho más probable cuando funcionan como sustantivos. Este tipo de consideraciones sugiere la segunda fuente de información: el simple conocimiento de la palabra concreta puede proporcionarnos datos muy valiosos acerca de la etiqueta correcta. La utilidad

de esta información fue demostrada de manera concluyente por Charniak, quien puso de manifiesto que un etiquetador que simplemente asigne la etiqueta más común a cada palabra puede alcanzar un índice de acierto del 90% [Charniak *et al.* 1993]. De hecho, el rendimiento de este etiquetador fue utilizado como referencia en todos los trabajos posteriores de esa época.

La información léxica de las palabras resulta tan útil porque la distribución de uso de una palabra a lo largo de todas sus posibles etiquetas suele ser rara. Incluso las palabras con un gran número de etiquetas aparecen típicamente con un único uso o etiqueta particular.

Efectivamente, esta distribución es tan peculiar que casi siempre existe esa etiqueta denominada *básica*, mientras que las otras representan usos derivados de ésta, y como resultado se han producido algunos conflictos en relación con la manera en la que el término *etiqueta*, *categoría* o *parte del discurso* debe ser utilizado. En las gramáticas tradicionales, se pueden encontrar palabras clasificadas como *un sustantivo que está siendo utilizado como un adjetivo*, lo cual confunde la etiqueta básica del lexema de la palabra, con la función real que dicha palabra está desempeñando dentro del contexto. Aquí, al igual que en la lingüística moderna en general, nos centraremos siempre en el segundo concepto, es decir, en el uso real de las palabras dentro de cada frase concreta.

En cualquier caso, la distribución de uso de las palabras proporciona una información adicional de gran valor, y es por ello por lo que parece lógico esperar que las aproximaciones estadísticas al proceso de etiquetación den mejores resultados que las aproximaciones basadas en reglas deterministas. En éstas últimas, uno sólo puede decir que una palabra puede o no puede ser un verbo, mientras que en una aproximación estadística se puede decir *a priori* que una palabra tiene una gran probabilidad de ser un sustantivo, pero también que existe una posibilidad, por remota que sea, de ser un verbo o incluso cualquier otra etiqueta. Sin embargo, en los últimos años, se han recuperado los métodos simbólicos y, con un pequeño replanteamiento, se han logrado unos resultados muy interesantes. Mientras que antes las reglas se utilizaban para cambiar la etiqueta de la palabra o para asignar una etiqueta dada según el contexto, ahora la idea consiste en reducir el uso de estas reglas y potenciar un nuevo tipo de reglas de menor compromiso, que consisten en eliminar etiquetaciones imposibles en lugar de asignar posibles etiquetas. Por ejemplo, si tenemos una palabra que puede ser verbo o sustantivo, y antes una que sólo puede ser determinante, debemos eliminar la posibilidad de etiquetar la palabra ambigua como verbo. Esto se puede llevar a cabo gracias a lenguajes de alta expresividad en los que se pueden contemplar casos conocidos del idioma y refinar así el conjunto de etiquetas que se le asignan a una palabra a través de un diccionario [Voutilainen y Heikkilä 1994, Tapanainen y Voutilainen 1994, Samuelsson y Voutilainen 1997].

De esta manera, se han conseguido resultados que superan al 99% de aciertos con un conjunto de unas 1.000 reglas aproximadamente. A pesar de esto, nos encontramos con el problema de que, como se trata de un método de menos compromiso que el anterior, no se garantiza la obtención de una única etiqueta por palabra, pudiendo quedar algunas palabras ambiguas a lo largo del texto. Por ello, este método se suele utilizar en combinación con otros sistemas de etiquetación.

En este proyecto describiremos los etiquetadores estocásticos y simbólicos más conocidos, y abordaremos el diseño de un sistema híbrido que considere la aplicación combinada de reglas contextuales con técnicas estocásticas. Es decir, utilizaremos de manera combinada la información sintagmática proporcionada por las secuencias de etiquetas y la información léxica proporcionada por las palabras, junto con todas las ventajas que nos ofrecen ambas aproximaciones.

1.2 Los primeros etiquetadores

Los trabajos que inicialmente se desarrollaron en relación con el proceso de etiquetación eran simplemente programas que buscaban la categoría de las palabras en un diccionario. El primer sistema conocido que realmente intentaba asignar etiquetas en función del contexto sintagmático es el programa basado en reglas presentado en [Klein y Simmons 1963], aunque aproximadamente la misma idea fue presentada también en [Salton y Thorpe 1962]. Klein y Simmons utilizan los términos *código* y *codificación*, aunque son aparentemente de uso intercambiable con *etiqueta* y *etiquetación*. El primer etiquetador probabilístico conocido es [Stolz *et al.* 1965]. Este sistema asignaba inicialmente etiquetas a algunas palabras mediante el uso de un diccionario, de reglas morfológicas y de otras reglas confeccionadas a medida. El resto de las palabras se etiquetaban entonces usando probabilidades condicionadas calculadas a partir de secuencias de etiquetas. Ni que decir tiene que no se trataba de un modelo probabilístico bien definido.

Dos grandes grupos de trabajo, uno en la Universidad Brown y otro en la Universidad de Lancaster, emplearon considerables recursos para etiquetar dos grandes *corpora* de texto: el corpus BROWN y el corpus LOB (Lancaster-Oslo-Bergen). Ambos grupos coincidieron en que la existencia de un corpus anotado sería de incalculable valor para la investigación en el campo de la etiquetación, y es cierto que sin estos dos *corpora* etiquetados el progreso de esta línea de trabajo hubiera sido extremadamente duro, si no imposible. La disponibilidad de grandes cantidades de texto etiquetado es sin lugar a dudas una importante razón que explica el hecho de que la etiquetación haya sido un área de investigación tan activa.

El corpus BROWN fue preetiquetado automáticamente con el etiquetador basado en reglas TAGGIT [Greene y Rubin 1971]. Esta herramienta utilizaba información léxica sólo para limitar las etiquetas de las palabras y sólo aplicaba reglas de etiquetación cuando las palabras del contexto no presentaban ambigüedades. La salida de este etiquetador se corrigió entonces manualmente. Este esfuerzo duró años, pero finalmente proporcionó los datos de entrenamiento que constituyeron la base de numerosos trabajos posteriores.

Uno de los primeros etiquetadores basado en modelos de Markov ocultos o HMM,s[3] fue creado en la Universidad de Lancaster como parte del proyecto de etiquetación del corpus LOB [Garside *et al.* 1987, Marshall 1987]. El punto central de este etiquetador era el manejo de probabilidades para las secuencias de bigramas de etiquetas, con uso limitado de un contexto de mayor orden, y las probabilidades de asignación de una palabra a sus diferentes etiquetas eran gestionadas mediante factores de descuento diseñados a medida. Los etiquetadores basados en modelos de Markov que etiquetan utilizando ambos tipos de información, las probabilidades de las palabras y las probabilidades de transición entre etiquetas, fueron introducidos en [Church 1988] y [DeRose 1988].

A pesar de que los trabajos de Church y DeRose fueron la clave del resurgir de los métodos estadísticos en lingüística computacional, la aplicación de los HMM,s al proceso de etiquetación había comenzado realmente mucho antes en los centros de investigación de IBM en Nueva York y París [Jelinek 1985, Derouault y Merialdo 1986]. Otras referencias de los primeros trabajos sobre etiquetación probabilística incluyen [Bahl y Mercer 1976, Baker 1975, Foster 1991].

En los últimos años, la etiquetación ha sido un área con una gran actividad dentro de la investigación en NLP, lo que ha permitido la aparición de otras técnicas para la etiquetación, como por ejemplo pueden ser las redes nueronales [Benello *et al.* 1989, Marques y Pereira 1996], los árboles de decisión [Schmid 1994], y el aprendizaje basado en memoria [Daelemans *et al.* 1996, Zavrel y Daelemans 1999]. De todas las técnicas más novedosas merece mención la que se basa en reglas reduccionistas, ya que uno de los objetivos

[3] *Hidden Markov Models.*

de este proyecto consiste en la mejora y utilización de las mismas para la eliminación de ambigüedades.

También nos podemos encontrar con trabajos orientados a la construcción de un corpus etiquetado con un mínimo esfuerzo humano [Brill *et al.* 1990]. Esto es un problema cuando no tenemos ningún corpus de entrenamiento equiquetado, o cuando a pesar de tenerlo, las aplicaciones trabajan con textos muy diferentes y los datos de entrenamiento son de poca utilidad. Otros estudios se han centrado en la manera de construir un conjunto de etiquetas automáticamente, con el propósito de crear categorías apropiadas para un idioma o para un estilo de texto particular [McMahon y Smith 1996].

1.3 Rendimiento y precisión de los etiquetadores

Las cifras de rendimiento conocidas para los etiquetadores se encuentran casi siempre dentro del rango del 95 al 97% de acierto, cuando se calculan sobre el conjunto de todas las palabras de un texto. Algunos autores proporcionan la precisión sólo para los términos ambiguos, en cuyo caso las cifras son por supuesto menores. Sin embargo, el rendimiento depende considerablemente de una serie de factores, tales como los siguientes:

- La cantidad de texto de entrenamiento disponible. En general, cuanto más texto se tenga, mejor.
- El juego de etiquetas[4]. Normalmente, cuanto más grande es el conjunto de etiquetas considerado, existe más ambigüedad potencial, y la tarea de etiquetación se vuelve más compleja. Por ejemplo, en inglés, algunos juegos de etiquetas hacen una distinción entre `to` como preposición y `to` como marca de infinitivo, y otros no. En el primero de los casos, la palabra `to` podría etiquetarse incorrectamente.
- La diferencia entre, por un lado el corpus de entrenamiento y el diccionario, y por otro el corpus de aplicación. Si los textos de entrenamiento y los textos que posteriormente se van a etiquetar proceden de la misma fuente, por ejemplo, textos de la misma época, o extraídos de un mismo periódico particular, entonces la precisión será alta. Normalmente, los resultados que los investigadores proporcionan sobre sus etiquetadores provienen de situaciones como ésta. Pero si los textos de aplicación pertenecen a un periodo de tiempo distinto, a una fuente distinta, o a un género o estilo distinto, por ejemplo, textos científicos contra textos periodísticos, entonces el rendimiento será bajo.
- Las palabras desconocidas. Un caso especial del punto anterior es la cobertura del diccionario. La aparición de palabras desconocidas puede degradar el rendimiento. Una situación típica en la cual el porcentaje de palabras fuera de vocabulario puede ser alto es cuando se intenta etiquetar material procedente de algún dominio técnico.

Un cambio en cualquiera de estas cuatro condiciones puede producir un impacto muy fuerte en la precisión de los etiquetadores, pudiendo provocar que el rendimiento se reduzca de manera dramática. Si el conjunto de entrenamiento es pequeño, el juego de etiquetas grande, y el corpus a etiquetar significativamente diferente del corpus de entrenamiento, o si nos enfrentamos a un gran número de palabras desconocidas, el rendimiento puede caer muy por debajo del rango de cifras citado anteriormente.

Es importante también señalar que efectivamente estos factores son externos al proceso de etiquetación y al método elegido para realizar dicho proceso. Es por ello que el efecto que producen es a menudo mucho mayor que la influencia ejercida por el propio método en sí.

[4] También denominado *tag set*.

1.4 Aplicaciones de la etiquetación

El amplio interés que ha surgido alrededor de la etiquetación está fundamentado en la creencia de que muchas aplicaciones de NLP se pueden beneficiar de los textos etiquetados. Sin embargo, aún conociendo esta motivación, resulta sorprendente el hecho de que existan más trabajos y referencias bibliográficas sobre el proceso de etiquetación aisladamente, que sobre la aplicación de los etiquetadores a tareas de interés inmediato. A pesar de esto, intentaremos enumerar aquí las aplicaciones más importantes en las que la etiquetación ha jugado y está jugando un papel relevante. Además de las citadas anteriormente, estas aplicaciones podrían ser las siguientes:

- La mayoría de las aplicaciones requieren un paso de procesamiento adicional posterior a la etiquetación: el análisis sintáctico parcial[5], que puede reflejar varios niveles de detalle dentro del análisis sintáctico. Los analizadores parciales más simples se limitan a buscar las frases nominales de una oración. Otras aproximaciones más sofisticadas asignan funciones gramaticales a esas frases nominales (sujeto, objeto directo, objeto indirecto, etc.) y al mismo tiempo proporcionan información parcial sobre las ligaduras[6]. Una presentación conjunta del análisis sintáctico parcial y de la etiquetación puede verse en [Abney 1996].

- Un uso importante de la combinación de la etiquetación y el análisis sintáctico parcial es el proceso de adquisición automática de información léxica[7]. El objetivo general de este proceso es desarrollar algoritmos y técnicas estadísticas para rellenar los huecos de información sintáctica y semántica que existen en los diccionarios electrónicos, mediante el estudio de los patrones de palabras que se pueden observar en grandes *corpora* de textos. Existen multitud de problemas relacionados con la adquisición de información léxica: la colocación de las palabras, las preferencias de selección[8], los marcos de subcategorización[9], o la categorización semántica[10]. La mayoría de este tipo de propiedades de las palabras no se suele cubrir completamente en los diccionarios. Esto es debido principalmente a la productividad de los lenguajes naturales: constantemente inventamos nuevas palabras o nuevos usos de las palabras que ya conocemos. Incluso aunque fuera posible crear un diccionario que reflejara todas las características del lenguaje actual, inevitablemente estaría incompleto en cuestión de pocos meses. Esta es la razón por la cual la adquisición automática de información léxica es tan importante en el NLP estadístico.

- Otra aplicación importante es la extracción de información[11]. El objetivo principal de la extracción de información es encontrar valores para un conjunto predeterminado de ranuras de información de una plantilla. Por ejemplo, una plantilla de información meteorológica podría tener ranuras para el tipo de fenómeno (tornado, tormenta de nieve, huracán), la localización del evento (la bahía coruñesa, Europa Central, Venezuela), la fecha (hoy, el próximo domingo, el 27 de diciembre de 1999), y el efecto causado (apagón general, inundaciones, accidentes de tráfico, etc.). La etiquetación y el análisis sintáctico parcial ayudan a identificar las entidades que sirven para rellenar las ranuras de información y las relaciones entre ellas. En cierta manera, podría verse la extracción de información como

[5] También denominado *partial parsing*.

[6] Por ejemplo, *esta frase nominal está ligada a otra frase de la derecha*, la cual puede aparecer especificada o no.

[7] También denominado *lexical acquisition*.

[8] Por ejemplo, el verbo `comer` normalmente lleva como objeto directo elementos relacionados con la comida.

[9] Por ejemplo, el beneficiario del verbo `contribuir` se expresa mediante una frase preposicional encabezada por la preposición `a`.

[10] Por ejemplo, cuál es la categoría semántica de una nueva palabra no presente en nuestro diccionario.

[11] O *information extraction*, y a veces también referenciada como *message understanding* (entendimiento del mensaje) o *data mining* (minería de datos).

un proceso de etiquetación donde las categorías son semánticas, en lugar de gramaticales. Sin embargo, en la práctica se tiende a emplear métodos bastante diferentes [Cardie 1997], ya que las secuencias locales proporcionan mucha menos información sobre categorías semánticas que sobre categorías gramaticales.

- La etiquetación y el análisis sintáctico parcial se pueden utilizar también para encontrar los términos de indexación adecuados en los sistemas de recuperación de información[12]. La mejor unidad de tratamiento para decidir qué documentos están relacionados con las consultas de los usuarios a menudo no es la palabra individual. Frases como `Estados Unidos de América` o `educación secundaria` pierden gran parte de su significado si se rompen en palabras individuales. El rendimiento de la recuperación de información se puede incrementar si la etiquetación y el análisis sintáctico parcial se dirigen hacia el reconocimiento de la frase nominal y si las asociaciones consulta-documento se realizan apoyándose en este tipo de unidad de información de más alto rango de significado [Fagan 1987, Smeaton 1992, Strzalkowski 1995]. Otra línea de investigación relacionada se ocupa de la normalización de frases, es decir, del estudio de las múltiples variantes de términos que representan realmente la misma unidad de información básica[13] [Jacquemin *et al.* 1997].

- Por último, existen también trabajos relacionados con los llamados sistemas de respuesta de preguntas[14], los cuales intentan responder a una cuestión del usuario devolviendo una frase nominal concreta, como por ejemplo un lugar, una persona o una fecha [Kupiec 1993, Burke *et al.* 1997]. Es decir, ante una pregunta como `¿quién mató a John Lennon?` obtendríamos como respuesta `Chapman`, en lugar de una lista de documentos tal y como ocurre en la mayoría de los sistemas de recuperación de información. Una vez más, el análisis de la consulta para determinar qué tipo de entidad está buscando el usuario y cómo está relacionada con las frases nominales que aparecen en la pregunta requiere etiquetación y análisis sintáctico parcial.

Terminamos, sin embargo, con un resultado no del todo positivo: los analizadores sintácticos probabilísticos mejor lexicalizados son hoy en día suficientemente buenos como para trabajar con texto no etiquetado y realizar la etiquetación por sí mismos, en lugar de utilizar un etiquetador como preprocesador [Charniak 1997]. Por tanto, el papel de los etiquetadores parece ser más bien el de un componente que aligera rápidamente la complejidad de los textos y proporciona suficiente información para multitud de interesantes tareas de NLP, y no el de una fase de preprocesado deseable e imprescindible para todas y cada unas de las aplicaciones.

1.5 Etiquetación mediante gramáticas de restricciones

En esta sección, hacemos una mención especial a las gramáticas de restricciones, porque en el presente proyecto se estudiará, analizará y mejorará la sintaxis de las reglas utilizadas por estas gramáticas, y además se desarrollará una forma de compilación y ejecución eficiente basada en traductores de estado finito. Por esta razón, resulta interesante el presentar una recopilación histórica de todos aquellos etiquetadores que hacen uso de este tipo de gramáticas.

Las gramáticas basadas en restricciones son una técnica en alza en estos últimos años. En concreto, una de las técnicas de etiquetación de mejor rendimiento para el inglés es un formalismo

[12] O también *information retrieval*.
[13] Por ejemplo, `book publishing` y `publishing of books`.
[14] También denominados *question answering systems*.

reduccionista no cuantitativo denominado sistema EngCG[15] o gramática de restricciones para el inglés, desarrollado en la Universidad del Helsinki [Voutilainen y Heikkilä 1994, Tapanainen y Voutilainen 1994, Samuelsson y Voutilainen 1997]. En este sistema encontramos un conjunto de reglas escritas a mano que manejan contexto global o, la mayoría de las veces, contexto local. No existe una verdadera noción de gramática formal, sino más bien un conjunto de restricciones, casi siempre negativas, que van eliminando los análisis imposibles según el contexto [Karlsson *et al.* 1995, Samuelsson *et al.* 1996]. La idea es similar al aprendizaje basado en transformaciones, excepto por el hecho de que es un humano, y no un algoritmo, el que modifica iterativamente el conjunto de reglas de etiquetación para minimizar el número de errores. En cada iteración, el conjunto de reglas se aplica al corpus y posteriormente se intentan modificar dichas reglas de manera que los errores más importantes queden manualmente corregidos. Esta metodología propone la construcción de un pequeño sistema experto para la etiquetación, y parece ofrecer mejores rendimientos que los etiquetadores basados en modelos de Markov ocultos, especialmente cuando los *corpora* de entrenamiento y de aplicación no provienen de la misma fuente. Sin embargo, la comparación de estos dos modelos es difícil de realizar, ya que cuando el sistema EngCG no es capaz de resolver determinadas ambigüedades devuelve un conjunto de más de una etiqueta. Por otra parte, para aquellas personas ya familiarizadas con esta metodología, la construcción de este tipo de etiquetadores no requiere más esfuerzo que la construcción de un etiquetador basado en un HMM [Chanod y Tapanainen 1995], aunque quizás, este último sea más accesible y automático. El problema de esta técnica es que hace falta un grupo de lingüistas que proporcionen las reglas, lo que supone un problema en comparación con el aprendizaje automático de los HMM,s. Sin embargo, los resultados son muy interesantes, aún a costa de no decidir en todas las etiquetas.

La Real Academia Española está desarrollando también un formalismo de reglas de restricciones denominado sistema Rtag, para la anotación automática de los *corpora* Corde[16] y Crea[17] [Porta 1996, Sánchez *et al.* 1999]. Este sistema aplica gramáticas de reglas de contexto ponderadas sobre textos anotados ambiguamente. Esto quiere decir que cuando un contexto satisface la descripción estructural de una regla, recibe la puntuación que indica la regla. Esta puntuación puede ser positiva, para promover lecturas, o negativa, para penalizarlas. Una vez finalizado el proceso, permanecen las lecturas con mayor puntuación siempre que estén por encima de un umbral definido previamente. El sistema también intenta eliminar lecturas imposibles en función del contexto, sin pérdida de lecturas posibles aunque éstas sean poco probables. Para la poda de lecturas en función del contexto se utiliza información derivada del propio texto (características estructurales, tipográficas o secuenciales), información gramatical (sobre todo concordancia y restricciones de aparición conjunta) e información gramatical estructural (toma de decisiones con ayuda de la información estructural derivable de la secuencia lineal del texto).

Otro etiquetador basado en gramáticas de restricciones que ha sido utilizado con éxito sobre el español es el sistema Relax [Padró 1996]. Aquí las reglas pueden ser escritas tanto de forma manual como generadas automáticamente mediante un algoritmo de adquisición basado en un árbol de decisión [Màrquez y Padró 1997, Màrquez y Rodríguez 1997].

1.6 Motivación y objetivos del proyecto

La etiquetación, como vimos anteriormente, se aborda a partir de recursos lingüísticos bajo la forma de diccionarios y textos previamente etiquetados o no, que serán utilizados para ajustar

[15] *English Constraint Grammar.*
[16] *Corpus Diacrónico del Español.*
[17] *Corpus de Referencia del Español Actual.*

los parámetros de funcionamiento de los etiquetadores. Dicho proceso de ajuste se denomina entrenamiento. Las técnicas estocásticas basadas en modelos Markov ocultos constituyen actualmente la aproximación que mejores rendimientos ofrece.

Básicamente, la aplicación de los HMM,s al proceso de etiquetación se realiza normalmente a nivel de frase. Para una nueva frase a etiquetar, se accede primeramente a un diccionario, en busca de todas las posibles etiquetas candidatas para cada una de las palabras que conforman dicha frase. Todas estas etiquetas individuales pueden involucrar a un gran número de posibles caminos o secuencias de etiquetación globales para la frase. Así pues, seguidamente, se construye una estructura en forma de enrejado capaz de albergar todas esas combinaciones. Por último, un algoritmo de programación dinámica, el algoritmo de Viterbi, es capaz de seleccionar de manera eficiente la secuencia o secuencias de etiquetas más probables.

No obstante, un pequeño porcentaje de palabras etiquetadas erróneamente (2-3%) es una característica siempre presente en los sistemas de etiquetación puramente estocásticos. Con el objetivo de reducir este porcentaje de errores residuales se acude a las reglas contextuales. De esta manera, el enrejado sobre el que opera el algoritmo de Viterbi va a poder ser podado por estas reglas, bien antes de aplicar el etiquetador estocástico, o bien después de aplicarlo.

A continuación indicamos de una forma más detallada los puntos que abordaremos en este primer objetivo del proyecto:

- Tomando como punto de partida el proyecto de fin de carrera [Reboredo y Graña 2000], se estudiarán y analizarán las reglas contextuales aquí desarrolladas, que se basan en las gramáticas de restricciones, con el propósito de simplificar su sintaxis y así facilitar el proceso de familiarización, entendimiento y uso de las mismas. Lo que se persigue con esto es facilitar el árido camino de comprensión de las reglas, para que así los lingüistas no sean tan reacios a proporcionar un conjunto de reglas contextuales, lo suficientemente grande y adecuado, para poder evaluar de una manera fiable, eficiente y completa nuestros sistemas.

- El siguiente punto a desarrollar consiste en la compilación de las reglas contextuales para lograr una ejecución lo más eficiente posible. Este proceso de compilación consiste en representar dichas reglas mediante una estructura matemática más compacta, que se denomina *traductor de estado finito*. Unido a esto surge la dificultad de que la teoría de traductores no está tan claramente especificada como la teoría de autómatas. Es decir, problemas tales como la minimización o determinización de los traductores constituyen líneas de trabajo vigentes hoy en día, ya que no existen algoritmos universales para resolverlos. Por tanto, tendremos que enfrentarnos al estudio y análisis en profundidad de todos estos aspectos que la teoría de traductores no refleja con claridad.

- Por último, se llevará a cabo la implementación de un prototipo que cumpla con las especificaciones anteriores. Cabe destacar que, en el momento de la realización de este proyecto, no se ha podido disponer de reglas contextuales elaboradas por expertos lingüistas. Si bien éstos han contribuido parcialmente en la mejora del formalismo de reglas, lo que no ha sido posible es evaluar el sistema sobre un conjunto de reglas reales. No obstante, la aplicación del prototipo sobre un caso de estudio sencillo permitirá validar el correcto funcionamiento del mismo. Por tanto, con el diseño e implementación de esta herramienta, queda preparado un sistema híbrido de etiquetación al que sólo le resta ser alimentado con reglas contextuales verdaderamente representativas del idioma que se quiera tratar.

Como segundo objetivo del presente proyecto abordaremos otra extensión natural de la aplicación de los HMM,s al proceso de etiquetación. En este caso se trata de integrar en el proceso de

etiquetación ciertas decisiones de segmentación o identificación de *tokens* que tradicionalmente se resuelven en fases anteriores. Dado que dichas decisiones se toman también en función del contexto, el objetivo es huir de la casuística particular que presentan algunos fenómenos léxicos, y poder así dotar de una solución más formal al proceso de segmentación.

Más concretamente, la mayoría de los etiquetadores actuales asumen que los textos aparecen ya correctamente segmentados, es decir, divididos en *tokens* que identifican perfectamente cada componente. Sin embargo, esta hipótesis de trabajo no es realista debido a la naturaleza heterogénea de los textos. Las mayores dificultades surgen cuando la segmentación es ambigua. Por ejemplo, la expresión `sin embargo` se etiquetará normalmente de manera conjunta como una conjunción, pero en algún otro contexto podría ser una secuencia formada por una preposición y un sustantivo. De igual forma, la palabra `ténselo` puede ser una forma del verbo `tener` con dos pronombres enclíticos, o bien una forma del verbo `tensar` con un solo pronombre.

Debido a estas segmentaciones ambiguas, un etiquetador debería ser capaz de enfrentarse a flujos de *tokens* de distinta longitud. Es decir, no sólo debería ser capaz de decidir qué etiqueta asignar a cada *token*, sino que además debería saber decidir si algunos de ellos constituyen o no una misma entidad y asignar, en cada caso, la cantidad de etiquetas adecuada en función de las diferentes alternativas de segmentación.

Básicamente, este segundo objetivo del proyecto involucra a las tareas que se enumeran a continuación:

- En primer lugar, será necesario definir una estructura capaz de representar coherentemente las distintas alternativas de segmentación que puede proporcionar un módulo de preprocesamiento ante una nueva frase. Veremos que los enrejados clásicos dejan de ser adecuados, por lo que serán sustituidos por una nueva estructura de representación denominada retículo[18].

- Posteriormente, abordaremos la adaptación del algoritmo tradicional de Viterbi, para que pueda trabajar sobre retículos, en lugar de sobre enrejados.

- Por último, este algoritmo sufrirá una nueva adaptación, que es la que efectivamente permitirá etiquetar flujos de *tokens* de distinta longitud con una complejidad temporal comparable a la del algoritmo de clásico.

La siguiente sección permitirá al lector situar los objetivos anteriormente mencionados a lo largo de los capítulos desarrollados en este documento.

1.7 Estructura de la presente memoria

Los contenidos fundamentales de este trabajo se dividen en cuatro partes claramente diferenciadas. A continuación introducimos cada una de ellas, centrándonos en el contenido de los capítulos que las conforman:

- La parte I engloba los conceptos preliminares sobre NLP en general, y sobre etiquetación en particular, necesarios para abordar el resto de los contenidos del documento. Además de la presente introducción, esta parte consta también del siguiente capítulo:

  - El capítulo 2 esboza las distintas técnicas existentes para la realización del análisis léxico de los textos. Este análisis transforma los caracteres de entrada en unidades de más alto nivel de significado, normalmente las palabras, y obtiene rápida y cómodamente todas las etiquetas candidatas de esas palabras. Por tanto, el análisis

[18] O también *lattice*.

léxico constituye un paso de procesamiento previo que simplifica tareas posteriores tales como la etiquetación o el análisis sintáctico.

- La parte II describe en profundidad dos de las principales estrategias que definen el estado actual del arte en lo que al proceso de etiquetación se refiere. Los capítulos que conforman esta parte son los siguientes:

  – El capítulo 3 se ocupa de los etiquetadores basados en modelos de Markov ocultos o HMM,s[19]. Los HMM,s presentan un conjunto de estados que normalmente coincide con el conjunto de etiquetas que se está considerando. La dependencia probabilística del estado o etiqueta actual generalmente se trunca para considerar sólo uno o dos de los estados o etiquetas precedentes (propiedad del horizonte limitado) y esta dependencia no varía a lo largo del tiempo (propiedad del tiempo estacionario). Esto quiere decir que si, por ejemplo, se ha establecido en 0,2 la probabilidad de que un verbo venga después de un pronombre al principio de una frase, dicha probabilidad es la misma para el resto de la frase e incluso para otras frases posteriores. Como ocurre con la mayoría de los modelos probabilísticos, las dos propiedades de Markov no formalizan la realidad a la perfección, pero constituyen una buena aproximación.

  – El capítulo 4 describe el sistema de etiquetación presentado por Eric Brill, que utiliza reglas de transformación tanto léxicas como contextuales [Brill 1993b]. Las reglas no se escriben a mano, sino que se generan automáticamente a partir de un corpus de entrenamiento mediante un procedimiento iterativo que, en cada etapa, selecciona las transformaciones que minimizan el número de errores cometidos. El procedimiento se repite hasta que dicho número cae por debajo de un cierto umbral. Este método de entrenamiento se denomina *aprendizaje basado en transformaciones y dirigido por el error*[20].

- La parte III engloba el primer objetivo del proyecto, con lo cual aquí presentaremos, estudiaremos y desarrollaremos todos los puntos necesarios que conllevan a la resolución del mismo. Para ello, nos apoyaremos en gramáticas de restricciones y *traductores de estado finito* principalmente. Los capítulos que conforman esta parte son los siguientes:

  – El capítulo 5 enfatiza la necesidad de acudir al contexto para mejorar la precisión de los métodos de etiquetación estocástios, e introduce la necesidad de un formalismo de reglas basado en gramáticas de restricciones. A continuación se estudia un lenguaje de reglas desarrollado para este propósito, que se conoce como lenguaje LEMMERS (Lenguaje de Etiquetado MEdiante Restricciones Simples). Sin embargo este formalismo, que es una mejora de las reglas que presentan las gramáticas de restricciones, todavía es complejo y difícil de entender. Por esta razón nosotros plantearemos aquí una mejora sobre la sintaxis de estas reglas para hacerlas más sencillas, intuitivas y expresivas.

  – El capítulo 6 se ocupa de la representación de los esquemas generales de reglas, introducidos en el capítulo anterior, a través de *traductores de estado finito*, ya que la compilación de las reglas bajo esta estructura matemática redunda en una ejecución más eficiente. Con lo cual, se indicarán los traductores generales que represetan los esquemas generales de las reglas junto con algunos ejemplos. También abordaremos el desarrollo y la implementación del prototipo encargado de llevar a cabo la compilación y la ejecución de las reglas contextuales, así como un caso de estudio para verificar

[19] *Hidden Markov Models.*
[20] *Transformation-based error-driven learning.*

el correcto funcionamiento del mismo. También indicaremos todas las operaciones sobre traductores necesarias y el orden de aplicación de las mismas para su correcto funcionamiento.

- La parte IV se centra en el segundo objetivo de este proyecto, de manera que presentaremos el proceso de segmentación, los problemas a los que se enfrenta y las soluciones que propone. También incluimos aquí el capítulo de conclusiones finales y trabajo futuro.
  - El capítulo 7 trata de explicar en qué consiste el proceso de segmentación y refleja que la identificación de los *tokens* que participan en una frase no es una operación tan sencilla como se cree de antemano, ya que puede haber ambigüedades. Para esto es necesario elaborar un sistema de etiquetación que asigne las etiquetas adecuadas en función de las diferentes alternativas de segmentación. Por esta razón, consideraremos una extensión del algoritmo de Viterbi para que tenga en cuenta estas indicaciones y aborde el problema de manera que no supere la complejidad temporal del algoritmo tradicional.
  - El capítulo 8 finaliza este estudio presentando las principales conclusiones extraídas y las líneas de trabajo futuro.

Finalmente, se incluyen los apéndices que contienen los aspectos complementarios, así como la lista de las referencias bibliográficas utilizadas a lo largo de este trabajo.

Capítulo 2

Análisis léxico de grandes diccionarios

El problema de la correcta etiquetación o del análisis sintáctico de una frase dada puede resultar complejo si se aborda tratando directamente el flujo de los caracteres de entrada que conforman esa frase. Para evitar dicha complejidad, normalmente existirá un paso de procesamiento previo, cuya misión es la de transformar el flujo de caracteres de entrada en un flujo de elementos de más alto nivel de significado[1], que típicamente serán las palabras de la frase en cuestión, y la de obtener rápida y cómodamente todas las etiquetas candidatas de esas palabras. Dicho paso previo se denomina análisis léxico[2].

Este capítulo está destinado a esbozar las distintas técnicas existentes para la realización de esta tarea. No obstante, comenzaremos presentando en detalle la visión particular que se ha utilizado a lo largo de este trabajo para modelizar los diccionarios, y la técnica concreta con la que se han implementado.

2.1 Modelización de un diccionario

Si bien es cierto que muchas de las palabras que aparecen en un diccionario se pueden capturar automáticamente a partir de los textos etiquetados, otras muchas serán introducidas manualmente por los expertos lingüistas, con el fin de cubrir de manera exhaustiva algunas categorías de palabras poco pobladas, que constituyen el núcleo invariable de un idioma (artículos, preposiciones, conjunciones, etc.), o alguna terminología particular correspondiente a un determinado ámbito de aplicación. Sin embargo, cuando nos enfrentamos a lenguajes naturales que presentan un paradigma de inflexión de gran complejidad, resulta impensable que el usuario tenga que introducir en el diccionario todas y cada una de las formas derivadas de un lema dado[3]. En lugar de esto, resulta mucho más conveniente realizar un estudio previo que identifique los diferentes grupos de inflexión (género, número, irregularidad verbal, etc.), de manera que a la hora de introducir posteriormente un nuevo término en el diccionario, el usuario sólo tenga que hacer mención de las raíces involucradas en él y de los grupos de inflexión mediante los cuales se realiza la derivación de formas desde cada una de esas raíces [Graña *et al.* 1994].

Por supuesto, una interfaz gráfica que genere temporalmente las formas correspondientes a la operación de inserción que se va a realizar, tal y como se muestra en la figura 2.1, puede resultar de gran ayuda para el usuario al permitirle comprobar si efectivamente está realizando

[1] Normalmente denominados *tokens*.

[2] O también *scanning*.

[3] Por ejemplo, el paradigma de conjugación verbal del español puede utilizar hasta 118 formas distintas para un mismo verbo.

la inserción de las raíces en el grupo correcto o no [Vilares *et al.* 1997]. Sin embargo, la representación inicial de un diccionario consiste en una base de datos que almacena la información léxica correspondiente sólo a las raíces y a sus grupos de inflexión correspondientes.

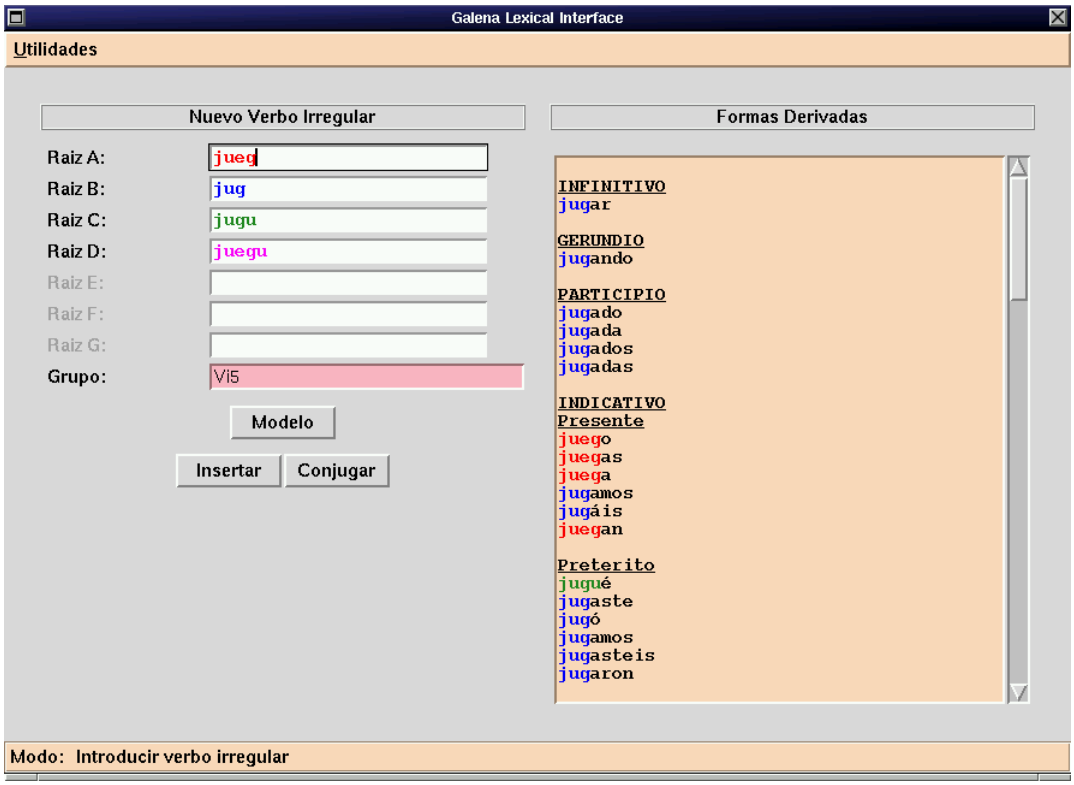

Figura 2.1: Interfaz gráfica para la introducción de términos en el diccionario

Sin embargo, en este punto surgen dos problemas:

1. El primero de ellos es un problema inherente al uso de bases de datos. Las bases de datos se presentan como herramientas válidas para el almacenamiento de gran cantidad de información estructurada, ya que resultan muy flexibles a la hora de realizar tareas de gestión y mantenimiento: las inserciones, actualizaciones, borrados y consultas se realizan mediante operaciones relacionales muy potentes que pueden implicar a uno o varios campos de información, de la misma o de diferentes tablas de datos. Pero cuando se procesan textos grandes, quizás de millones de palabras, no sólo interesa un acceso flexible a los datos, sino también un acceso muy rápido, y una base de datos no es el mejor mecanismo a la hora de recuperar este tipo de información, y menos aún si en ella residen las raíces y no las palabras concretas que aparecen en los textos. Existen mecanismos mucho más eficientes para esta última tarea, como pueden ser los autómatas finitos que describiremos en la siguiente sección.

2. El segundo de los problemas es que muchas aplicaciones necesitan incorporar información adicional relativa a las palabras, no a las raíces. Tal es el caso de determinados paradigmas de etiquetación estocástica o de análisis sintáctico estocástico, que necesitan asociar una probabilidad a cada una de las combinaciones posibles palabra-etiqueta. Por ejemplo, en el contexto de los modelos de Markov ocultos, que veremos más adelante, esa probabilidad representa la *probabilidad de emisión* de la palabra dentro del conjunto de todas las palabras que tienen esa misma etiqueta. O bien, dentro del marco del análisis

sintáctico estocástico, esa misma probabilidad puede verse como la probabilidad de la regla gramatical *etiqueta* → *palabra*. Así que una vez más, la información de las raíces no es suficiente. Necesitamos disponer de todas las palabras que se pueden generar a partir de esas raíces. El mismo procedimiento que aparece en la interfaz gráfica de introducción de raíces se puede también utilizar aquí para generar todas las palabras y, posteriormente, a través de otro procedimiento para la estimación de las probabilidades, que veremos con detalle en el próximo capítulo, podemos integrar toda la información necesaria, de manera que resida junta en un mismo recurso.

Por lo tanto, en este segundo momento, nuestra visión de un diccionario o lexicón es simplemente un fichero de texto, donde cada línea tiene el siguiente formato:

```
palabra etiqueta lema probabilidad
```

Las palabras ambiguas, es decir, con varias etiquetaciones posibles, utilizarán una línea diferente para cada una de esas etiquetas.

Ejemplo 2.1 Sin pérdida de generalidad, las palabras podrían estar ordenadas alfabéticamente, de tal manera que, en el caso del diccionario del sistema GALENA [Vilares *et al.* 1995], el punto donde aparece la ambigüedad de la palabra `sobre` presenta el siguiente aspecto[4]:

```
...
sobraste V2sei0 sobrar 0.00162206
sobrasteis V2pei0 sobrar 0.00377715
sobre P sobre 0.113229
sobre Scms sobre 0.00126295
sobre Vysps0 sobrar 0.0117647
sobrecarga Scfs sobrecarga 0.00383284
sobrecarga V2spm0 sobrecargar 0.00175131
sobrecarga V3spi0 sobrecargar 0.000629723
sobrecargaba Vysii0 sobrecargar 0.0026455
...
```

El diccionario del sistema GALENA presenta 291.604 palabras diferentes, con 354.007 etiquetaciones posibles. Esta última cifra es precisamente el número de líneas del fichero anterior. Para una discusión posterior, diremos ahora que la primera etiquetación de la palabra `sobre`, es decir, como preposición,

```
sobre P sobre 0.113229
```

aparece en la línea 325.611 dentro de ese fichero. Y diremos también que, en el conjunto de todas las 291.604 palabras diferentes ordenadas alfabéticamente, la palabra `sobre` ocupa la posición 268.249. □

Por supuesto, ésta tampoco es todavía la versión operativa final de un diccionario. El problema del acceso eficiente a los datos sigue aún presente, pero éste es un problema que, como ya hemos dicho, resolveremos en la siguiente sección. Lo realmente importante ahora es obtener una versión compilada que represente de una manera más compacta todo este gran volumen de información. Esta versión compilada y su forma de operar se muestran en la figura 2.2, donde se pueden identificar cada uno de los siguientes elementos:

[4]Las etiquetas a las que se hace referencia en este y futuros capítulos pertenecen al sistema GALENA y para ver su significado se puede consultar el apéndice A.1

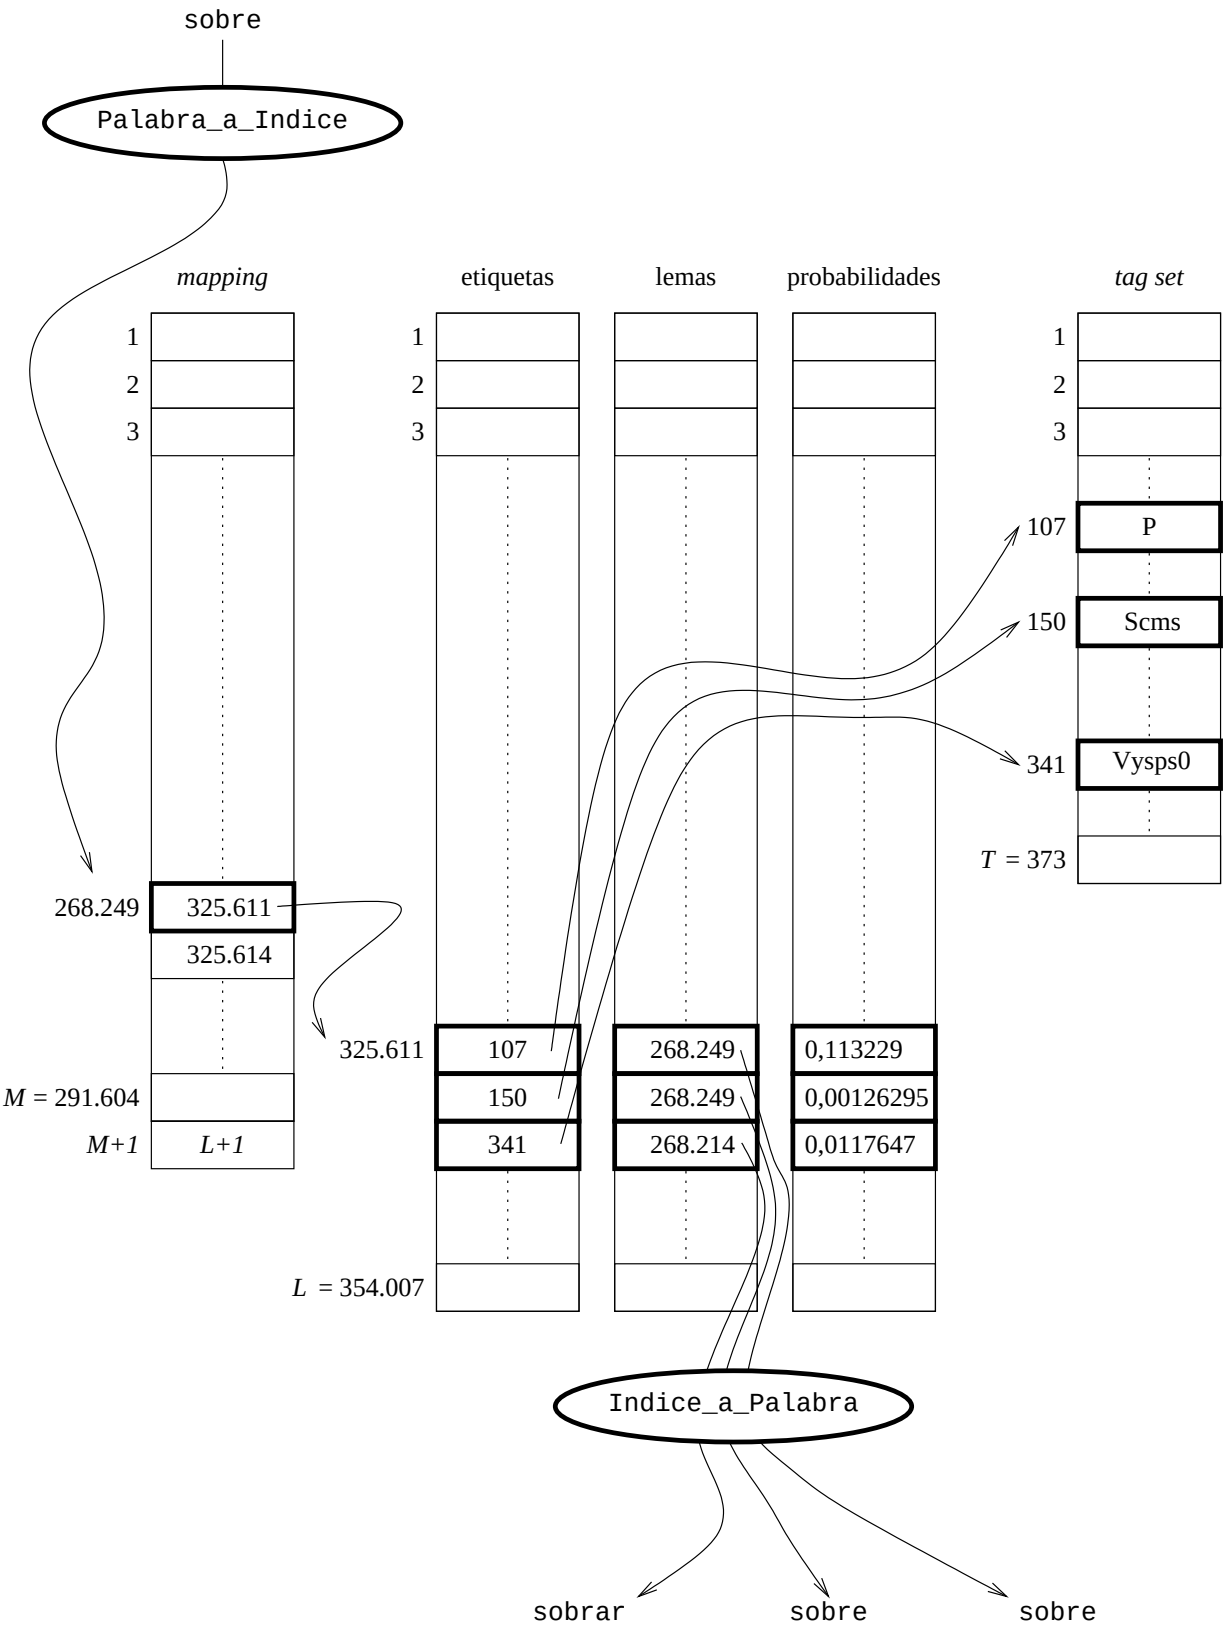

Figura 2.2: Modelización compacta de un diccionario

- La función `Palabra_a_Índice`, que explicaremos con detalle en la siguiente sección, es capaz de convertir una palabra en un número que representa la posición que ocupa esa palabra dentro del conjunto de todas las palabras diferentes ordenadas alfabéticamente. Por ejemplo, esta función transforma `sobre` en el número 268.249.

- Ese número sirve para indexar un tablero de correspondencia[5] de tamaño $M + 1$, que transforma la posición relativa de cada palabra en la posición absoluta dentro del lexicón original. En el caso del diccionario del sistema GALENA, M es igual a 291.604, el número de palabras distintas. En el caso de `sobre`, la posición relativa 268.249 se transforma en la posición absoluta 325.611.

- Ese número sirve para indexar los tableros de *etiquetas*, *lemas* y *probabilidades*. Todos estos tableros son de tamaño L. En el caso del diccionario del sistema GALENA, L es igual a 354.007, el número de etiquetaciones distintas.

- El tablero de *etiquetas* almacena números. Una representación numérica de las etiquetas es más compacta que los nombres de las etiquetas en sí. Las etiquetas originales se pueden recuperar indexando con esos números el tablero del juego de etiquetas[6]. El tablero del juego de etiquetas tiene un tamaño T. En el caso del diccionario del sistema GALENA, T es igual a 373, el número de etiquetas distintas.

  Dado que hemos partido de una ordenación alfabética, está garantizado que las etiquetas de una misma palabra aparecen contiguas. No obstante, necesitamos saber de alguna manera dónde terminan las etiquetas de una palabra dada. Para ello, es suficiente con restarle el valor de la posición absoluta de la palabra al valor de la siguiente casilla en el tablero de correspondencia. En nuestro caso, la palabra `sobre` tiene $325.614 - 325.611 = 3$ etiquetas. Esta operación es también válida para acceder correctamente a la información de los tableros de *lemas* y *probabilidades*.

- El tablero de *lemas* almacena también números. Un lema es una palabra que debe estar también presente en el diccionario. El número que la función `Palabra_a_Índice` obtendría para esa palabra es el número que se almacena aquí, siendo esta representación mucho más compacta que el lema en sí. El lema se puede recuperar aplicando la función `Índice_a_Palabra`, que explicaremos con detalle en la siguiente sección.

- El tablero de *probabilidades* almacena directamente las probabilidades. En este caso no es posible realizar ninguna compactación.

Ésta es por tanto la representación más compacta que se puede diseñar para albergar toda la información léxica relativa a las palabras presentes en un diccionario. Es además una representación muy flexible en el sentido de que resulta particularmente sencillo incorporar nuevos tableros, si es que se necesita algún otro tipo de información adicional. Por ejemplo, algunas aplicaciones de lexicografía computacional que realicen estudios sobre el uso de un idioma podrían utilizar un tablero de números enteros que almacene la frecuencia de aparición de las palabras en un determinado texto. De igual manera, aquellos tableros que no se utilicen se pueden eliminar, con el fin de ahorrar su espacio correspondiente[7].

Por otra parte, ideando un nuevo método de acceso o una nueva disposición de los elementos de los tableros, es también sencillo transformar esta estructura en un generador de formas, es

[5] O tablero de *mapping*.

[6] O tablero de *tag set*.

[7] Por ejemplo, no todas las aplicaciones hacen uso del lema y de la probabilidad, pudiendo ser suficiente sólo con las etiquetas.

decir, en un mecanismo bidireccional que no sólo reconozca palabras, sino que también, dado un lema y una etiqueta, genere la forma flexionada correspondiente. Esta funcionalidad es indispensable en aplicaciones de generación de lenguaje, es decir, en aquellas aplicaciones donde el flujo de información que va desde el sistema hacia el usuario se realiza utilizando lenguaje natural [Vilares *et al.* 1996a].

Otro aspecto más de la flexibilidad de esta representación es el que se describe a continuación. Cuando al procesar un texto aparece una palabra que no está presente en nuestro diccionario, el tratamiento normal será asumir que es desconocida y posteriormente intentar asignarle la etiqueta que describe su papel en la frase, igual que si se tratara de una palabra normal. La diferencia radica en que para la palabra desconocida no podemos obtener un conjunto inicial de etiqueta candidatas, de manera que habrá que definir una serie de categorías *abiertas* que permitan inicializar dicho conjunto. Sin embargo, hay aplicaciones en las que puede ser más conveniente suponer que todas las categorías están *cerradas* y que por tanto esa palabra es realmente una palabra del diccionario, pero que presenta algún error lexicográfico que hay que corregir. Ocurre entonces que el hecho de tener la información de etiquetación totalmente separada del mecanismo de reconocimiento de las palabras en sí facilita la posterior incorporación de algoritmos de corrección automática de este tipo de errores lexicográficos [Vilares *et al.* 1996b].

Finalmente, para completar la modelización de diccionarios que hemos presentado, sólo nos resta detallar la implementación de las funciones `Palabra_a_Índice` e `Índice_a_Palabra`. Ambas funciones trabajan sobre un tipo especial de autómatas finitos, los autómatas finitos acíclicos deterministas numerados, que se describen a continuación.

2.2 Autómatas finitos acíclicos deterministas numerados

La manera más eficiente de implementar analizadores léxicos[8] es quizás mediante el uso de autómatas finitos [Hopcroft y Ullman 1979]. La aplicación más tradicional de esta idea la podemos encontrar en algunas de las fases de construcción de compiladores para los lenguajes de programación [Aho *et al.* 1985]. El caso del procesamiento de los lenguajes naturales es cuantitativamente diferente, ya que surge la necesidad de representar diccionarios léxicos que muchas veces pueden llegar a involucrar a cientos de miles de palabras. Sin embargo, el uso de los autómatas finitos para las tareas de análisis y reconocimiento de las palabras sigue siendo una técnica perfectamente válida.

Definición 2.1 Un *autómata finito* es una estructura algebraica que se define formalmente como una 5-tupla $A = (Q, \Sigma, \delta, q_0, F)$, donde:

- Q es un conjunto finito de estados,
- Σ es un alfabeto finito de símbolos de entrada, es decir, el alfabeto de los caracteres que conforman las palabras,
- δ es una función del tipo $Q \times \Sigma \rightarrow P(Q)$ que define las transiciones del autómata,
- q_0 es el estado inicial del autómata, y
- F es el subconjunto de Q al que pertenecen los estados que son finales.

El estado o conjunto de estados que se alcanza mediante la transición etiquetada con el símbolo a desde el estado q se denota como $q.a = \delta(q, a)$. Cuando este estado es único, es decir, cuando la función δ es del tipo $Q \times \Sigma \rightarrow Q$, se dice que el autómata finito es *determinista*. □

[8] También denominados *scanners*.

La anterior notación es transitiva, es decir, si w es una palabra de n letras, entonces $q.w$ denota el estado alcanzado desde q utilizando las transiciones etiquetadas con cada una de las letras w_1, w_2, ..., w_n de w. Una palabra w es aceptada por el autómata si $q_0.w$ es un estado final.

Definición 2.2 Se denota como $L(A)$ el *lenguaje reconocido por el autómata* A, es decir, el conjunto de todas las palabras w tales que $q_0.w \in F$. □

Definición 2.3 Un autómata finito es *acíclico* cuando su grafo subyacente es acíclico. Los autómatas finitos acíclicos reconocen lenguajes formados por conjuntos finitos de palabras. □

2.2.1 Construcción del autómata

La primera estructura que nos viene a la mente para implementar un reconocedor de un conjunto finito de palabras dado es un *árbol de letras*.

Ejemplo 2.2 El árbol de letras de la figura 2.3 reconoce todas las formas de los verbos ingleses `discount`, `dismount`, `recount` y `remount`, es decir, el conjunto finito de palabras[9]:

```
discount     discounted     discounting     discounts
dismount     dismounted     dismounting     dismounts
recount      recounted      recounting      recounts
remount      remounted      remounting      remounts
```

Esta estructura es en sí misma un autómata finito acíclico determinista, donde el estado inicial es el 0 y los estados finales aparecen marcados con un círculo más grueso. □

Como en todo autómata finito, la complejidad de reconocimiento de un árbol de letras es lineal respecto a la longitud de la palabra a analizar, y no depende para nada ni del tamaño del diccionario, ni del tamaño de dicho autómata.

Sin embargo, los requerimientos de memoria de esta estructura de árbol pueden llegar a ser elevadísimos cuando el diccionario es muy grande. Por ejemplo, el dicionario del sistema Galena necesitaría un árbol de más de un millón de nodos para reconocer las 291.604 palabras diferentes. Por tanto, en lugar de utilizar directamente esta estructura, le aplicaremos un proceso de minimización para obtener otro autómata finito con menos estados y menos transiciones. Los autómatas finitos tienen una propiedad que garantiza que este proceso de minimización siempre se puede llevar a cabo, y que además el nuevo autómata resultante es equivalente, es decir, reconoce exactamente el mismo conjunto de palabras que el autómata original [Hopcroft y Ullman 1979]. Por otra parte, en el caso de los autómatas finitos acíclicos deterministas, este proceso de minimización es particularmente sencillo, tal y como veremos más adelante.

Ejemplo 2.3 El autómata finito acíclico determinista mínimo correspondiente al árbol de letras de la figura 2.3 es el que se muestra en la figura 2.4. □

Por otra parte, y debido una vez más a esos mismos requerimientos de memoria, no resulta conveniente construir un diccionario insertando primero todas y cada una de las palabras en un árbol de letras y obteniendo después el autómata mínimo correspondiente a dicho árbol. En lugar de esto, es mucho más aconsejable realizar varias etapas de inserción y minimización. Por tanto, la construcción del autómata se realiza de acuerdo con los pasos básicos del siguiente algoritmo.

[9] El símbolo **#** que aparece en las figuras denota el fin de palabra.

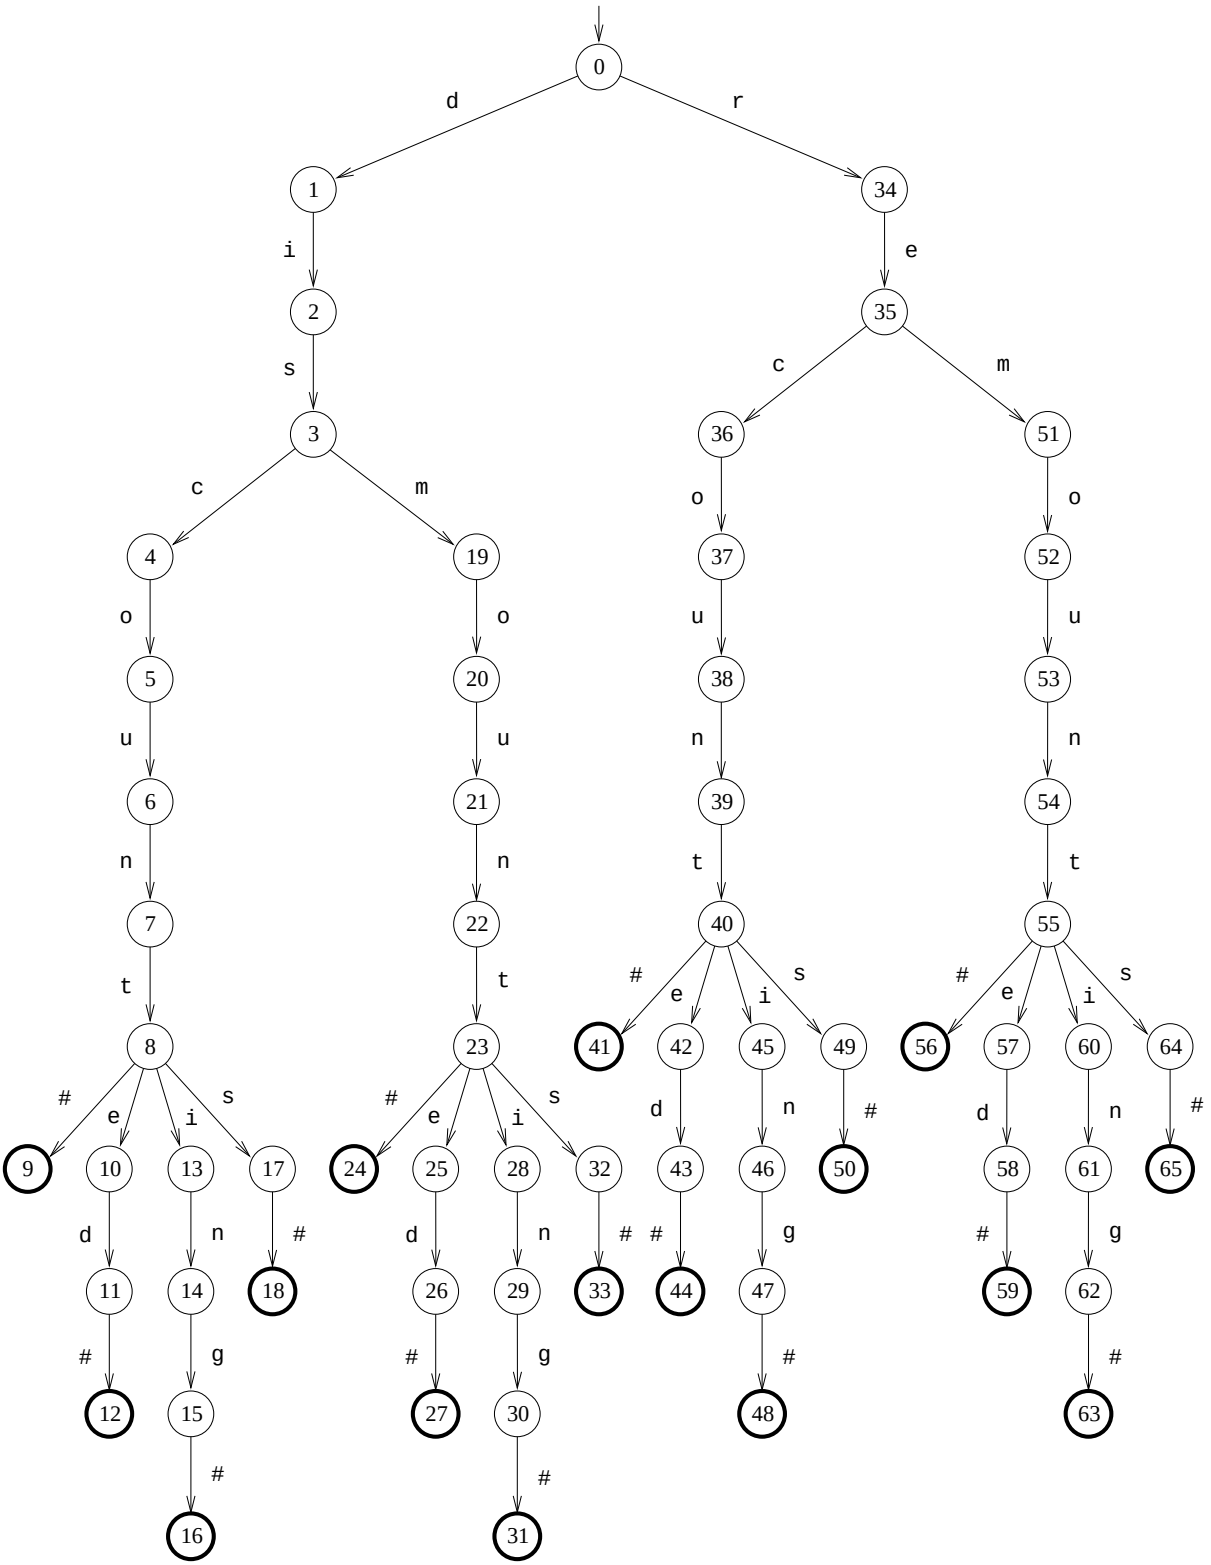

Figura 2.3: Árbol de letras para las formas de los verbos `discount`, `dismount`, `recount` y `remount`

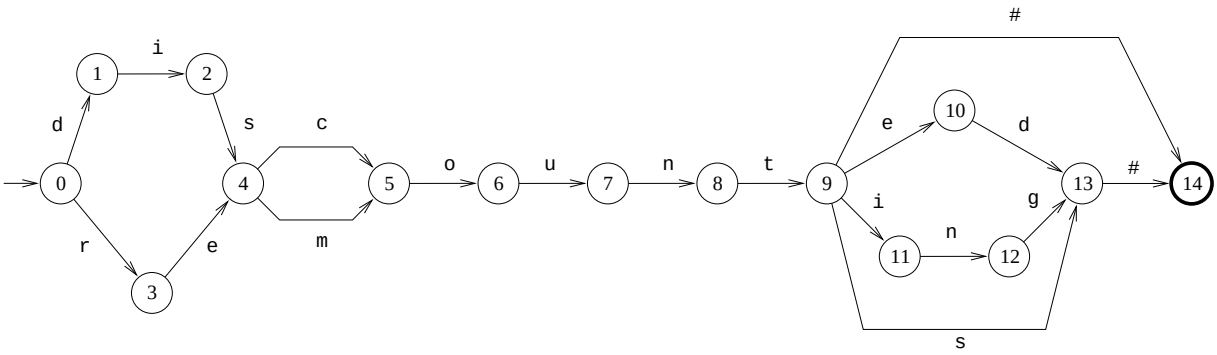

Figura 2.4: Autómata finito acíclico determinista mínimo para las formas de los verbos `discount`, `dismount`, `recount` y `remount`

Algoritmo 2.1 Algoritmo para la construcción de un autómata finito acíclico determinista a partir de un lexicón:

function *Construir_Autómata* (*Lexicón*) =
  begin
    $A \leftarrow Autómata_Vacío$;

    while (*queden palabras del Lexicón por insertar*) **do**
      begin
        if (*A está lleno*) **then**
          $A \leftarrow Minimizar_Autómata\ (A)$;
        Insertar la siguiente palabra del Lexicón en A
      end;

    $A \leftarrow Minimizar_Autómata\ (A)$;
    return A
  end;

Eligiendo un tamaño máximo previo para el autómata, este algoritmo de construcción permite que los consumos tanto de memoria como de tiempo por parte de los procesos de inserción y minimización sean muchísimo más moderados. □

Ejemplo 2.4 Fijando el tamaño máximo en 65.536 estados[10], el proceso de construcción del autómata finito acíclico determinista mínimo para el diccionario del sistema Galena necesitó 10 etapas de inserción y minimización. La evolución de dicho proceso se puede observar en la figura 2.5. □

En este momento es importante indicar cómo se debe realizar la correcta inserción de nuevas palabras en un autómata durante el proceso de construcción del mismo. Dicha inserción se puede llevar a cabo mediante una sencilla operación recursiva que hace uso de las transiciones que ya han aparecido, con el fin de compartir los caminos ya existentes en el grafo. Pero ocurre que este procedimiento *estándar* de inserción sólo es válido para los árboles de letras, y realmente nuestro

[10]La razón para elegir este número como cota superior del tamaño del autómata es que es el número máximo de enteros diferentes que se pueden almacenar en dos *bytes* de memoria, y además se ha comprobado empíricamente que resulta adecuado ya que con cotas mayores los pasos de minimización se alargan excesivamente, y con cotas menores el número de palabras que se pueden insertar en cada etapa de construcción es muy pequeño y como consecuencia el número de etapas necesarias crece considerablemente.

Etapa de construcción	Palabras insertadas	Antes de la minimización Estados	Transiciones	Después de la minimización Estados	Transiciones
1	34.839	65.526	100.363	2.277	5.219
2	68.356	65.527	101.986	4.641	11.431
3	100.325	65.526	104.285	6.419	16.163
4	132.094	65.530	107.043	7.377	18.560
5	163.426	65.532	108.047	8.350	21.094
6	193.368	65.525	108.211	9.858	24.877
7	223.743	65.530	110.924	10.646	27.166
8	253.703	65.527	112.007	11.221	28.850
9	283.281	65.528	112.735	11.779	30.617
10	291.604	26.987	54.148	11.985	31.258

Figura 2.5: Evolución del proceso de construcción del autómata finito acíclico determinista mínimo para el diccionario del sistema GALENA

autómata sólo es un árbol de letras antes de la primera minimización. Si el procedimiento de inserción estándar se aplica después de minimizar, es decir, cuando el autómata ya no es un árbol de letras, las inserciones pueden dar lugar a errores de construcción.

Ejemplo 2.5 Tal es el caso de la inserción que se plantea en la figura 2.6. Nuestra intención aquí es incorporar la palabra `removal` en el autómata de la figura 2.4. Si añadimos esta nueva palabra mediante un procedimiento de inserción estándar, éste aprovecha la existencia del camino $0 \xrightarrow{\texttt{r}} 3 \xrightarrow{\texttt{e}} 4 \xrightarrow{\texttt{m}} 5 \xrightarrow{\texttt{o}} 6$ para añadir el menor número posible de nuevos estados y transiciones, y la operación degenera recursivamente en la inserción de la subpalabra `val` en el subautómata que comienza en el estado 6. Aparentemente todo es correcto, pero si nos fijamos bien observaremos que de repente hemos hecho válida no sólo la palabra `removal` sino también las palabras `discoval`, `dismoval` y `recoval`, lo cual no era nuestra intención, y además dichas palabras no existen en inglés. □

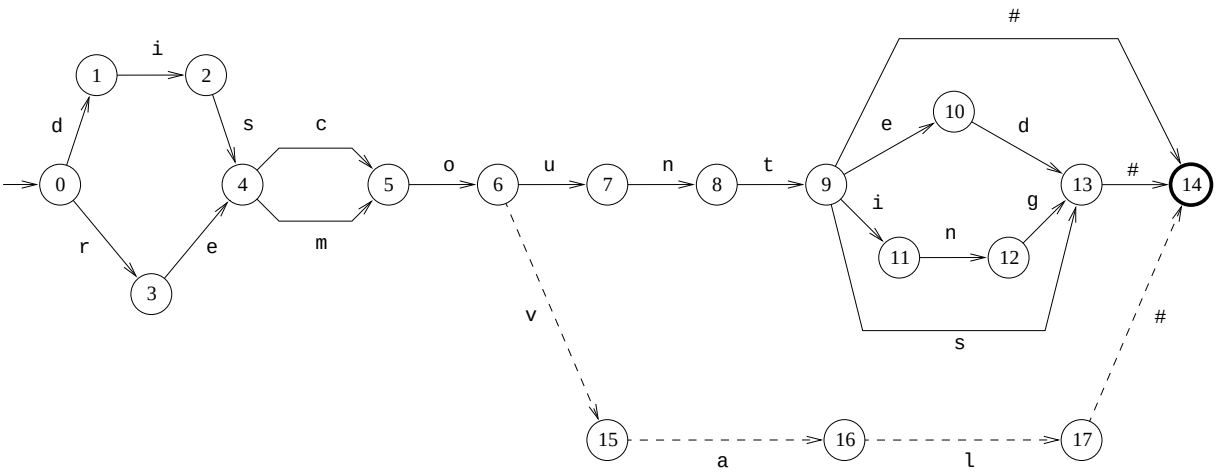

Figura 2.6: El problema de la inserción de nuevas palabras en un autómata finito acíclico determinista

La solución al problema planteado pasa por diseñar un nuevo procedimiento de inserción *especial*. Dicho procedimiento comprueba en todo momento que está haciendo uso de transiciones

cuyo estado destino tiene una única transición entrante. Si se llega a un estado con más de una transición entrante, entonces se trata de un estado al que se puede llegar también al menos por otro camino distinto al que está recorriendo el proceso de inserción en ese momento. Si esto ocurre, entonces ese estado problemático se duplica, el estado destino de la transición implicada se cambia por el estado copia, y se continúa recursivamente la inserción de la palabra en el subautómata que comienza en este nuevo estado.

Ejemplo 2.6 Como se puede observar en la figura 2.7, esta operación de duplicado de un estado podría ser necesario realizarla más de una vez durante el proceso de inserción de una misma palabra, ya que es posible que se alcancen varias veces estados con más de una transición entrante, en nuestro caso, los estados 4, 5 y 6. □

Aparentemente, esta operación de rotura y duplicación de determinadas partes del autómata contradice el objetivo perseguido, que es el de obtener el autómata mínimo. Pero a medida que se inserten más y más palabras irán apareciendo nuevos fenómenos léxicos subceptibles de ser compartidos durante la siguiente aplicación del proceso de minimización.

En cualquier caso, lo que sí es importante señalar es que este procedimiento de inserción especial es más complejo que el procedimiento de inserción estándar. Pero ocurre que si insertamos las palabras en el autómata según su orden alfabético, entonces está garantizado que sólo es necesario aplicar el procedimiento de inserción especial a la primera palabra que aparece después de cada minimización, pudiéndose realizar el resto de inserciones con el procedimiento estándar. La demostración de esta afirmación es sencilla de razonar: si después de una inserción especial, al intentar insertar una nueva palabra, aparece algún estado problemático con más de una transición entrante, necesariamente dicha inserción ha de corresponder a una palabra lexicográficamente menor a la última palabra insertada en el autómata, y dado que las palabras se insertan en orden alfabético dicha palabra no puede aparecer.

Ejemplo 2.7 Si observamos otra vez la figura 2.7, es fácil comprobar intuitivamente que la inserción de cualquier palabra lexicográficamente mayor que `removal` caerá por debajo del camino de líneas punteadas y no pasará por ningún estado problemático, y por tanto se puede insertar normalmente en el autómata como si de un árbol de letras se tratara. □

En el momento en que el autómata se llena de nuevo, se realiza una minimización, una inserción especial, y se continúa con el proceso hasta que todas las palabras del lexicón hayan sido insertadas.

2.2.2 El algoritmo de minimización de la altura

Para definir formalmente el algoritmo de minimización, es necesario introducir primero los siguientes conceptos.

Definición 2.4 Se dice que dos autómatas son *equivalentes* si y sólo si reconocen el mismo lenguaje. Se dice también que dos estados p y q de un autómata dado son *equivalentes* si y sólo si el subautómata que comienza con p como estado inicial y el que comienza con q son equivalentes. O lo que es lo mismo, si para toda palabra w tal que $p.w$ es un estado final, entonces $q.w$ es también un estado final, y viceversa. □

Definición 2.5 El concepto contrario es que dos estados p y q se dicen *distinguibles* o *no equivalentes* si y sólo si existe una palabra w tal que $p.w$ es un estado final y $q.w$ no lo es, o viceversa. □

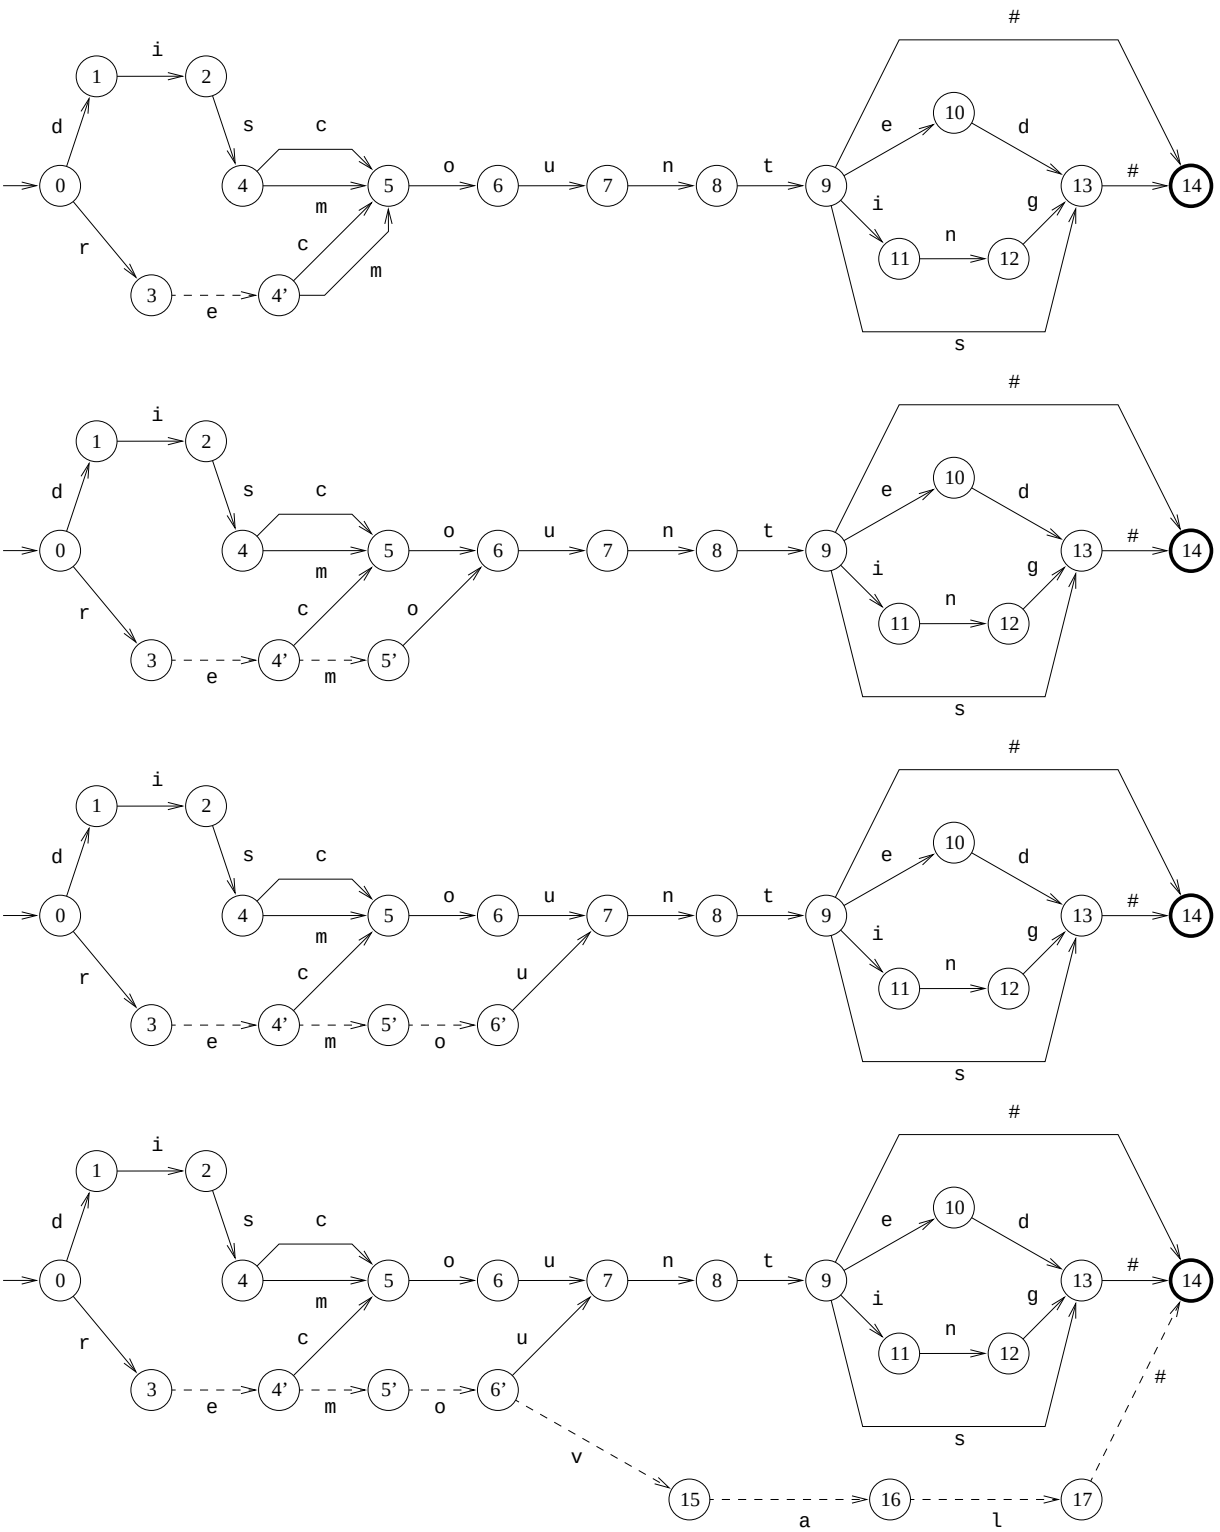

Figura 2.7: Inserción correcta de nuevas palabras en un autómata finito acíclico determinista

Definición 2.6 Si A es un autómata, existe un único autómata M, mínimo en el número de estados, que reconoce el mismo lenguaje, es decir, tal que $L(A) = L(M)$. Un autómata *mínimo* es aquél que no contiene ningún par de estados equivalentes. Y un autómata mínimo para un lenguaje dado L es por tanto aquél que contiene el menor número de estados posible de entre todos los autómatas que reconocen L. □

Definición 2.7 Si denotamos la *altura* de un estado s como $h(s)$, entonces $h(s) = max\{|w| \text{ tal que } s.w \in F\}$. Es decir, la altura de un estado s es la longitud del camino más largo de entre todos los que empiezan en dicho estado s y terminan en alguno de los estados finales. Esta función de altura establece una partición Π sobre Q, de tal manera que Π_i denota el conjunto de todos los estados de altura i. Diremos que el conjunto Π_i es *distinguible* si todos sus estados son *distinguibles*, es decir, si no contiene ningún par de estados equivalentes. □

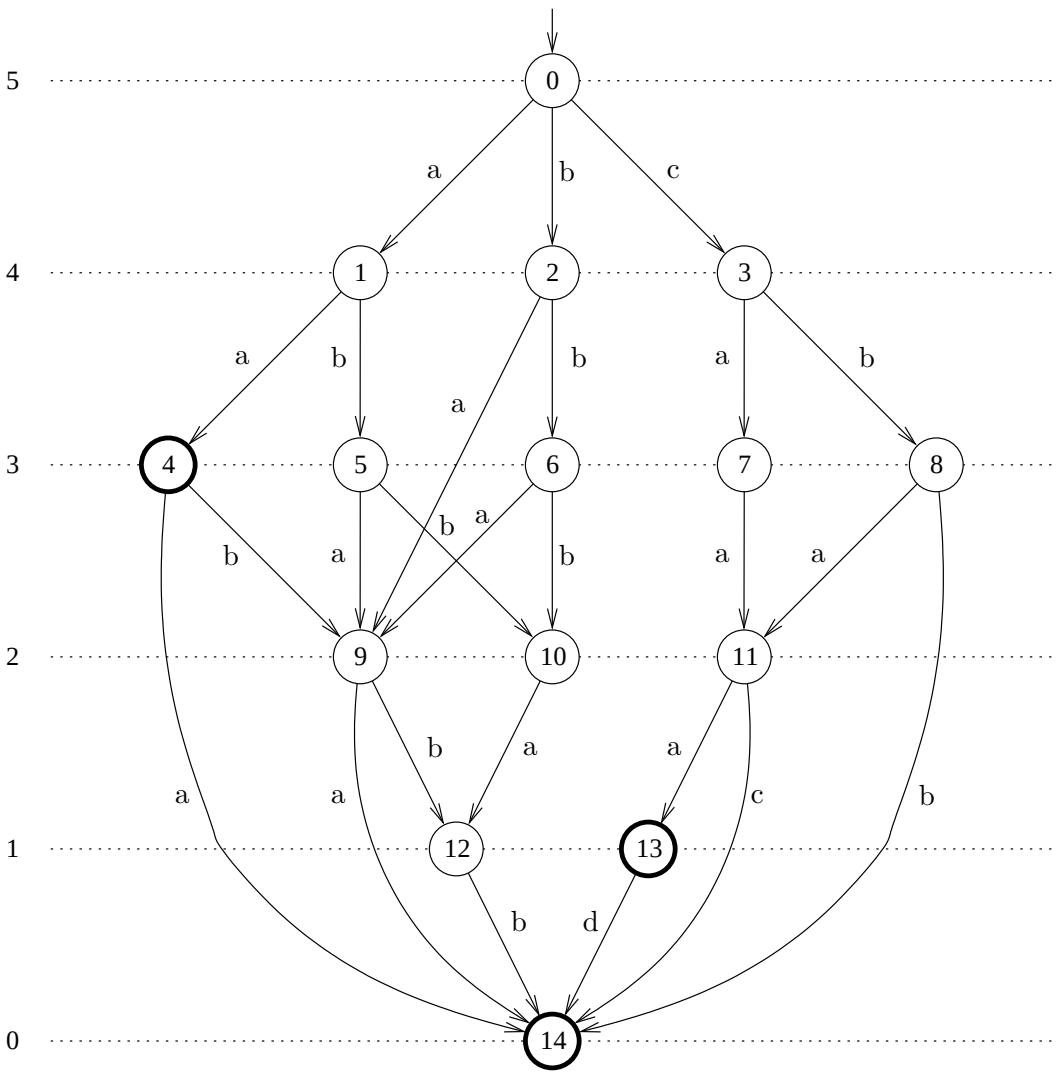

Figura 2.8: Un autómata finito acíclico determinista no mínimo

Ejemplo 2.8 La figura 2.8 muestra un autómata finito acíclico determinista, donde el estado inicial es el 0 y los estados finales son el 4, el 13 y el 14, y que por tanto reconoce el lenguaje $L = \{aa, aaa, aaba, aabbb, abaa, ababb, abbab, baa, babb, bbaa, bbabb, bbbab, caaa, caaad, caac,$

cbaa, *cbaad*, *cbac*, *cbb*}. Los estados de la misma altura aparecen conectados por una línea punteada horizontal. Este autómata no es mínimo, ya que los estados 5 y 6 de altura 3 son equivalentes. Podemos colapsar dichos estados en uno solo eliminando uno de ellos, por ejemplo el 5, y cambiando el estado destino de sus transiciones entrantes por el otro estado, es decir, cambiando la transición $1 \xrightarrow{b} 5$ por $1 \xrightarrow{b} 6$. □

Una vez que ha sido definida la altura de un estado, estamos en condiciones de introducir el siguiente teorema.

Teorema 2.1 Si todos los Π_j con $j < i$ son distinguibles, entonces dos estados p y q pertenecientes a Π_i son equivalentes si y sólo si para cualquier letra $a \in \Sigma$ la igualdad $p.a = q.a$ se verifica.

Demostración: Si dicha igualdad se verifica, los estados son equivalentes, por la propia definición de estado equivalente. Así que para la demostración de esta propiedad, basta estudiar los casos en los que dicha igualdad no se verifica, y comprobar que efectivamente los estados no son equivalentes. Entonces, dados p y q dos estados de Π_i con $p.a \neq q.a$, tenemos dos posibilidades:

1. Cuando $p.a$ y $q.a$ pertenecen al mismo Π_j. Dado que $j < i$, que el autómata es acíclico, y que por hipótesis todos los estados de Π_j son distinguibles, entonces p y q también son distinguibles.

2. Cuando $p.a \in \Pi_j$ y $q.a \in \Pi_k$, $j \neq k$. Supongamos sin pérdida de generalidad que $k < j$. Entonces, por la definición de Π, existe una palabra w de longitud j tal que $(p.a).w$ es final y $(q.a).w$ no lo es. Por tanto, los estados $p.a$ y $q.a$ son distinguibles, y entonces p y q también son distinguibles.

Este resultado se conoce también como la *propiedad de la altura*. □

El algoritmo de minimización se puede deducir ahora de manera sencilla a partir de la propiedad de la altura [Revuz 1992].

Algoritmo 2.2 Los pasos básicos del algoritmo de minimización de un autómata finito acíclico determinista son los siguientes:

```
procedure Minimizar_Autómata (Autómata) =
  begin
    Calcular Π;

    for i ← 0 to h(q0) do
      begin
        Ordenar los estados de Πi según sus transiciones;
        Colapsar los estados equivalentes
      end
  end;
```

Primero creamos la partición del conjunto de estados según su altura. Esta partición se puede calcular mediante un recorrido recursivo estándar sobre el autómata, cuya complejidad temporal es $\mathcal{O}(t)$, donde t es el número de transiciones del autómata. No obstante, si el autómata no es un árbol, se puede ganar algo de velocidad mediante una marca que indique si la altura de un estado ha sido ya calculada o no. De igual manera, los estados no útiles no tendrán ninguna altura asignada y ya se pueden eliminar durante este recorrido. Posteriormente, se procesa cada uno de los Π_i, desde $i = 0$ hasta la altura del estado inicial, ordenando los estados según sus transiciones y colapsando los estados que resulten ser equivalentes. □

Utilizando un esquema de ordenación de complejidad temporal $\mathcal{O}(f(e))$, donde e es el número de elementos a ordenar, el algoritmo 2.2 presenta una complejidad

$$\mathcal{O}(t + \sum_{i=0}^{h(q_0)} f(|\Pi_i|))$$

que en el caso de los autómatas finitos acíclicos deterministas es menor que la complejidad del algoritmo general de Hopcroft para cualquier tipo de autómatas finitos deterministas: $\mathcal{O}(n \times \log n)$, donde n es el número de estados [Hopcroft y Ullman 1979].

2.2.3 Asignación y uso de los números de indexación

Hemos visto que los autómatas finitos acíclicos deterministas son la estructura más compacta que se puede diseñar para el reconocimiento de un conjunto finito de palabras dado. Los resultados de compresión son excelentes, y el tiempo de reconocimiento es lineal respecto a la longitud de la palabra a analizar, y no depende ni del tamaño del diccionario, ni del tamaño del autómata.

Sin embargo, si detenemos el proceso de construcción del autómata en este punto, dispondremos de una estructura que solamente es capaz de indicarnos si una palabra dada pertenece o no al diccionario, y esto no es suficiente para el esquema de modelización de diccionarios que hemos desarrollado anteriormente. Dicha modelización necesita un mecanismo que transfome cada palabra en una clave numérica unívoca, y viceversa.

Definición 2.8 Esta transformación se puede llevar a cabo fácilmente si el autómata incorpora, para cada estado, un entero que indique el número de palabras que se pueden aceptar mediante el subautómata que comienza en ese estado [Lucchesi y Kowaltowski 1993]. Nos referiremos a este autómata como *autómata finito acíclico determinista numerado.* □

Ejemplo 2.9 La versión numerada del autómata de la figura 2.4 es la que se muestra en la figura 2.9. □

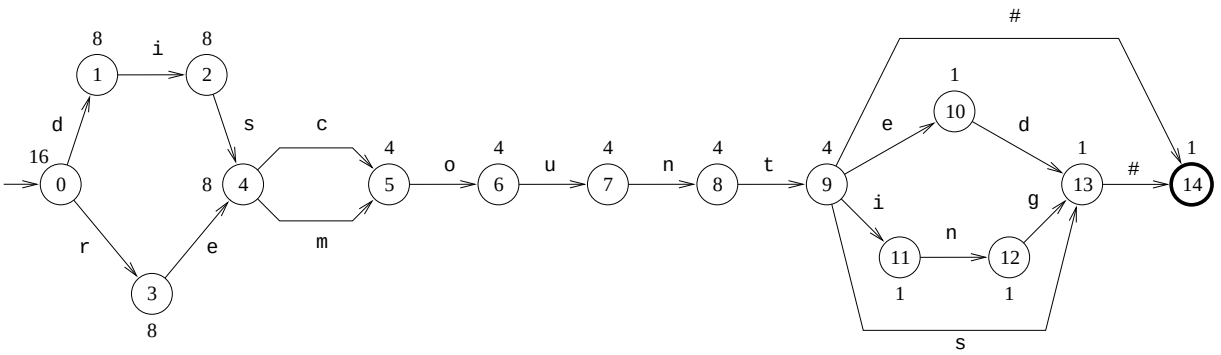

Figura 2.9: Autómata finito acíclico determinista mínimo numerado para las formas de los verbos `discount`, `dismount`, `recount` y `remount`

La asignación de los números de indexación a cada estado se puede realizar mediante un sencillo recorrido recursivo sobre el autómata, una vez que éste ha sido correctamente construido y minimizado. Por tanto, la versión definitiva de la función `Construir_Autómata` es la que se muestra a continuación.

Algoritmo 2.3 Algoritmo para la construcción de un autómata finito acíclico determinista a partir de un lexicón:

```
function Construir_Autómata (Lexicón) =
  begin
    A ← Autómata_Vacío;

    while (queden palabras del Lexicón por insertar) do
      if (A está lleno) then
        begin
          A ← Minimizar_Autómata (A);
          Inserción especial de la siguiente palabra del Lexicón en A
        end
      else
        Inserción estándar de la siguiente palabra del Lexicón en A;

    A ← Minimizar_Autómata (A);
    Asignar los números de indexación a los estados de A;
    return A
  end;
```

Este nuevo proceso de construcción del autómata completa y substituye al visto anteriormente en el algoritmo 2.1. □

Una vez que el autómata ha sido numerado, podemos ya escribir las funciones `Palabra_a_Índice` e `Índice_a_Palabra`, que son las que realizan la correspondencia uno a uno entre las palabras del diccionario y los números 1 a M, donde M es el número de total de palabras distintas aceptadas por el autómata.

Algoritmo 2.4 Pseudo-código de la función `Palabra_a_Índice`:

```
function Palabra_a_Índice (Palabra) =
  begin
    Índice ← 1;
    Estado_Actual ← Estado_Inicial;

    for i ← 1 to Longitud (Palabra) do
      if (Transición_Válida (Estado_Actual, Palabra[i])) then
        begin
          for c ← Primera_Letra to Predecesor (Palabra[i]) do
            if (Transición_Válida (Estado_Actual, c)) then
              Índice ← Índice + Estado_Actual[c].Número;
          Estado_Actual ← Estado_Actual[Palabra[i]];
        end
      else
        return palabra desconocida;

    if (Es_Estado_Final (Estado_Actual)) then
      return Índice
    else
      return palabra desconocida
  end;
```

Esta función parte con un índice igual a 1 y va transitando por el autómata desde el estado inicial utilizando cada una de las letras de la palabra a analizar. En cada uno de los estados por los que pasa el camino correspondiente a dicha palabra, el índice se va incrementando con el número de indexación del estado destino de aquellas transiciones que son lexicográficamente precedentes a la transición utilizada. Si después de procesar todos los caracteres de la palabra llegamos al estado final, entonces el índice contendrá la clave numérica de la palabra. En caso contrario, la palabra no pertenece al lexicón que se está manejando. Como consecuencia, el valor del índice no es correcto, y en su lugar la función devuelve un valor que indica que la palabra es desconocida. □

Algoritmo 2.5 Pseudo-código de la función `Índice_a_Palabra`:

```
function Índice_a_Palabra (Índice) =
  begin
    Estado_Actual ← Estado_Inicial;
    Número ← Índice;
    Palabra ← Palabra_Vacía;
    i ← 1;

    repeat
      for c ← Primera_Letra to Última_Letra do
        if (Transición_Válida (Estado_Actual, c)) then
          begin
            Estado_Auxiliar ← Estado_Actual[c];
            if (Número > Estado_Auxiliar.Número) then
              Número ← Número − Estado_Auxiliar.Número
            else
              begin
                Palabra[i] ← c;
                i ← i + 1;
                Estado_Actual ← Estado_Auxiliar;
                if (Es_Estado_Final (Estado_Actual)) then
                  Número ← Número − 1;
                exit forloop
              end
          end
      until (Número = 0);

      return Palabra
  end;
```

Esta función parte del índice y realiza las operaciones análogas a las del algoritmo 2.4, para deducir cuáles son las transiciones que dan lugar a ese índice, y a partir de esas transiciones obtiene las letras que forman la palabra que se está buscando. □

Ejemplo 2.10 En el caso del autómata numerado de la figura 2.9, la correspondencia individual de cada palabra con su índice es como sigue:

```
 1 <-> discount    2 <-> discounted     3 <-> discounting    4 <-> discounts
 5 <-> dismount    6 <-> dismounted     7 <-> dismounting    8 <-> dismounts
 9 <-> recount    10 <-> recounted     11 <-> recounting    12 <-> recounts
13 <-> remount    14 <-> remounted     15 <-> remounting    16 <-> remounts
```

Se puede observar que M, en este caso 16, corresponde efectivamente con el número de indexación del estado inicial, que es el que indica el número total de palabras que puede reconocer el autómata. □

Los requerimientos de almacenamiento y la complejidad temporal extra en el proceso de reconocimiento implicada por la incorporación de los números de indexación resulta modesta. Así que finalmente sólo nos queda hacer una pequeña referencia a las prestaciones de nuestro analizador léxico: el autómata finito acíclico determinista numerado correspondiente al diccionario GALENA consta de 11.985 estados y 31.258 transiciones; el tamaño del fichero compilado correspondiente a dicho autómata es de 3.466.121 *bytes*; el tiempo de compilación es de aproximadamente 29 segundos; y la velocidad de reconocimiento en una máquina con un procesador Pentium II a 300 MHz bajo sistema operativo Linux es de aproximadamente 40.000 palabras por segundo.

2.2.4 Algoritmos de construcción incrementales

Como hemos visto, los métodos tradicionales para la construcción de autómatas finitos acíclicos deterministas mínimos a partir de un conjunto de palabras consisten en combinar dos fases de operación: la construcción de un árbol o de un autómata parcial, y su posterior minimización. Sin embargo, existen métodos de construcción incremental, capaces de realizar las operaciones de minimización en línea, es decir, al mismo tiempo que se realizan las inserciones de las palabras en el autómata [Daciuk *et al.* 2000]. Estos métodos son mucho más rápidos, y sus requerimientos de memoria son también significativamente menores que los de los métodos descritos anteriormente.

Para construir un autómata palabra a palabra de manera incremental es necesario combinar el proceso de minimización con el proceso de inserción de nuevas palabras. Por tanto, hay dos preguntas cruciales que hay que responder:

1. ¿Qué estados, o clases de equivalencia de estados, son subceptibles de cambiar cuando se insertan nuevas palabras en el autómata?

2. ¿Existe alguna manera de minimizar el número de estados que es necesario cambiar durante la inserción de una palabra?

Como ya sabemos, si las palabras están ordenadas lexicográficamente, cuando se añade una nueva, sólo pueden cambiar los estados que se atraviesan al aceptar la palabra insertada previamente. El resto del autómata permanece inalterado, ya que la nueva palabra:

- O bien comienza con un símbolo diferente del primer símbolo de todas las palabras ya presentes en el autómata, con lo cual el símbolo inicial de la nueva palabra es situado lexicográficamente después de todos esos símbolos.

- O bien comparte algunos de los símbolos iniciales de la palabra añadida previamente. En este caso, el algoritmo localiza el último estado en el camino de ese prefijo común y crea una nueva rama desde ese estado. Esto es debido a que el símbolo que etiqueta la nueva transición será lexicográficamente mayor que los símbolos del resto de transiciones salientes que ya existen en ese estado.

Por tanto, cuando la palabra previa es prefijo de la nueva palabra a insertar, los únicos estados que pueden cambiar son los estados del camino de reconocimiento de la palabra previa que no están en el camino del prefijo común. La nueva palabra puede tener una finalización igual a la de otras palabras ya insertadas, lo cual implica la necesidad de crear enlaces a algunas partes del autómata. Esas partes, sin embargo, no se verán afectadas.

A continuación describimos el algoritmo de construcción incremental a partir de un conjunto de palabras ordenado lexicográficamente. Dicho algoritmo se apoya en una estructura denominada *Registro* que mantiene en todo momento un único representante de cada una de las clases de equivalencia de estados del autómata. Es decir, el *Registro* constituye en sí mismo el autómata mínimo en cada instante.

Algoritmo 2.6 El algoritmo de construcción incremental de un autómata finito acíclico determinista, a partir de un conjunto de palabras ordenado lexicográficamente, consta básicamente de dos funciones: la función principal *Construir_Autómata_Incremental* y la función *Reemplazar_o_Registrar*. Los pasos de la función principal son los siguientes:

```
function Construir_Autómata_Incremental (Lexicón) =
  begin
    Registro ← ∅;

    while (queden palabras del Lexicón por insertar) do
      begin
        Palabra ← siguiente palabra del Lexicón en orden lexicográfico;
        Prefijo_Común ← Prefijo_Común (Palabra);
        Último_Estado ← q0.Prefijo_Común;
        Sufijo_Actual ← Palabra[(Longitud (Prefijo_Común) + 1) ... Longitud (Palabra)];
        if (Tiene_Hijos (Último_Estado)) then
          Registro ← Reemplazar_o_Registrar (Último_Estado, Registro);
        Añadir_Sufijo (Último_Estado, Sufijo_Actual);
      end;

    Registro ← Reemplazar_o_Registrar (q0, Registro);
    return Registro
  end;
```

El esquema de la función *Reemplazar_o_Registrar* es como sigue:

```
function Reemplazar_o_Registrar (Estado, Registro) =
  begin
    Hijo ← Último_Hijo (Estado);
    if (Tiene_Hijos (Hijo)) then
      Registro ← Reemplazar_o_Registrar (Hijo, Registro);
    if (∃ q ∈ Q : q ∈ Registro ∧ q ≡ Hijo) then
      begin
        Último_Hijo (Estado) ← q;
        Eliminar (Hijo)
      end
    else
      Registro ← Registro ∪ Hijo;
    return Registro
  end;
```

El lazo principal del algoritmo lee las palabras y establece qué parte de cada palabra está ya en el autómata, es decir, el *Prefijo_Común*, y qué parte no está, es decir, el *Sufijo_Actual*. Un paso importante es determinar cuál es el último estado en el camino del prefijo común, que en el algoritmo se denota como *Último_Estado*. Si *Último_Estado* ya tiene hijos, quiere decir que no

todos los estados del camino de la palabra añadida previamente están en el camino del prefijo común. En ese caso, mediante la función *Reemplazar_o_Registrar*, hacemos que el proceso de minimización trabaje sobre los estados del camino de la palabra añadida previamente que no están en el camino del prefijo común. Posteriormente, añadimos desde el *Último_Estado* una cadena de nuevos estados capaz de reconocer el *Sufijo_Actual*.

La función *Prefijo_Común* busca el prefijo más largo de la palabra a insertar que es prefijo de alguna palabra ya insertada. La función *Añadir_Sufijo* crea una nueva rama que extiende el autómata, la cual representa el sufijo no encontrado de la palabra que se va a insertar. La función *Último_Hijo* devuelve una referencia al estado alcanzado por la última transición en orden lexicográfico que sale del estado argumento. Dado que los datos de entrada están ordenados, dicha transición es la transición añadida más recientemente en el estado argumento, durante la inserción de la palabra previa. La función *Tiene_Hijos* es cierta si y sólo si el estado argumento tiene transiciones salientes.

La función *Reemplazar_o_Registrar* trabaja efectivamente sobre el último hijo del estado argumento. Dicho argumento es el último estado del camino del prefijo común, o bien el estado inicial del autómata en la última llamada de la función principal. Es necesario que el estado argumento cambie su última transición en aquellos casos en los que el hijo va a ser reemplazado por otro estado equivalente ya registrado. En primer lugar, la función se llama recursivamente a sí misma hasta alcanzar el final del camino de la palabra insertada previamente. Nótese que cada vez que se encuentra un estado con más de un hijo, siempre se elige el último. La longitud limitada de las palabras garantiza el fin de la recursividad. Por tanto, al volver de cada llamada recursiva, se comprueba si ya existe en el registro algún estado equivalente al estado actual. Si es así, el estado actual se reemplaza por el estado equivalente encontrado en el registro. Si no, el estado actual se registra como representante de una nueva clase de equivalencia. Es importante destacar que la función *Reemplazar_o_Registrar* sólo procesa estados pertenecientes al camino de la palabra insertada previamente, y que esos estados no se vuelven a procesar. □

Durante la construcción, los estados del autómata o están en el registro o están en el camino de la última palabra insertada. Todos los estados del registro son estados que formarán parte del autómata mínimo resultante. Así pues, el número de estados durante la construcción es siempre menor que el número de estados del autómata resultante más la longitud de la palabra más larga. Por tanto, la complejidad espacial del algoritmo es $\mathcal{O}(n)$, es decir, la cantidad de memoria que precisa el algoritmo es proporcional a n, el número final de estados del autómata mínimo. Respecto al tiempo de ejecución, éste es dependiente de la estructura de datos implementada para manejar las búsquedas de estados equivalentes y las inserciones de nuevos estados representantes en el registro. Utilizando criterios de búsqueda e inserción basados en el número de transiciones salientes de los estados, en sus alturas y en sus números de indexación, los cuales se pueden también calcular dinámicamente, la complejidad temporal se puede rebajar hasta $\mathcal{O}(\log n)$.

Con este algoritmo incremental, el tiempo de construcción del autómata correspondiente al diccionario del sistema Galena se reduce considerablemente: de 29 segundos a 2,5 segundos, en una máquina con un procesador Pentium II a 300 MHz bajo sistema operativo Linux. La incorporación de la información relativa a las etiquetas, lemas y probabilidades consume un tiempo extra aproximado de 4,5 segundos, lo que hace un tiempo de compilación total de 7 segundos.

En el mismo trabajo, los autores proponen también un método incremental para la construcción de autómatas finitos acíclicos deterministas mínimos a partir de conjuntos de palabras no ordenados [Daciuk *et al.* 2000]. Este método se apoya también en la clonación o duplicación de los estados que se van volviendo conflictivos a medida que aparecen las nuevas palabras. Por esta razón, la construcción incremental a partir de datos desordenados es más lenta y consume más memoria que la construcción incremental a partir de esos mismos datos

ordenados. No obstante, el método puede ser de gran utilidad en situaciones donde el tamaño de los diccionarios es tan elevado que el propio proceso de ordenación podría resultar problemático.

2.3 Otros métodos de análisis léxico

Los procesos productivos o derivativos presentes en todos los idiomas constituyen una gran fuente de complicaciones para el análisis morfológico. Debido a ellos, siempre existirán multitud de palabras que no estarán incluidas en un diccionario morfológico estático, sin importar lo grande o preciso que éste sea. En otras palabras, se podría decir que el tamaño del lexicón de cualquier lengua es virtualmente infinito. Inevitablemente, éste es un problema al que deben enfrentarse los etiquetadores. Tal y como veremos con detalle en los capítulos siguientes, todo etiquetador debe incluir un módulo de tratamiento de palabras desconocidas, independientemente de los mecanismos que tenga integrados para el análisis léxico y para el acceso al diccionario.

Pero efectivamente, muchas de las palabras desconocidas serán formas derivadas a partir de una raíz y de una serie de reglas de inflexión. Por ejemplo, es muy probable que la palabra `reanalizable` no esté incluida en un diccionario dado, pero parece claro que esta palabra es parte del lenguaje, en el sentido de que puede ser utilizada, es comprensible y podría ser fácilmente deducida a partir de la palabra `analizar`[11] y de reglas de derivación tales como la incorporación de prefijos o la transformación de los verbos en sus respectivos adjetivos de calidad.

Además, no siempre es necesario manejar una información tan particular para cada palabra concreta como puede ser su frecuencia o su probabilidad. Fuera de los paradigmas de aproximación estocástica al NLP, la mayoría de las aplicaciones utilizan sólo la etiqueta, o como mucho la etiqueta y el lema. En esta última sección, por tanto, enumeramos brevemente otros posibles métodos de análisis léxico que han sido desarrollados.

La aproximación quizás más importante, y que ha servido de base para multitud de trabajos relacionados con la construcción automática de analizadores léxicos a partir de la especificación de las reglas morfológicas de flexión y derivación de una determinada lengua, es el modelo de *morfología de dos niveles*[12] [Koskenniemi 1983]. Este modelo se basa en la distinción tradicional que hacen los lingüistas entre, por un lado, el conjunto teórico de morfemas y el orden en el cual pueden ocurrir, y por otro lado, las formas alternativas que presentan dichos morfemas dentro del contexto fonológico en el que aparecen. Esto establece la diferencia entre lo que se denomina la *cadena superficial* del lenguaje (por ejemplo, la palabra `quiero`), y su correspondiente *cadena léxica* o *teórica* (en este caso, `quero` = `quer` + `o`). Por tanto, `quer` y `quier` se consideran alomorfos o formas alternativas del mismo morfema. El modelo de Koskenniemi es de dos niveles en el sentido de que cualquier palabra se puede representar mediante una correspondencia directa letra a letra entre su cadena de superficie y la cadena teórica subyacente.

Ejemplo 2.11 Para la palabra inglesa `skies`, podemos asumir que existe una raíz `sky` y una terminación de plural `-es`, salvo que, como ocurre en inglés con todos los sustantivos terminados en `y`, la `y` se realiza como una `i`, y por tanto las cadenas teórica y superficial serían, respectivamente:

```
s k y - e s
s k i 0 e s
```

En este ejemplo, el `-` inidica el límite de morfemas, y el `0` un caracter nulo o no existente. □

[11] Suponiendo que ésta sí está presente en el lexicón.
[12] *Two-level morphology.*

Posibles representaciones de las correspondencias letra a letra son `s:s` (no necesaria, porque por defecto cada letra se corresponde consigo misma, y por tanto dicha relación se puede expresar simplemente como `s`), o bien `-:0`, o también `y:i`. Respecto a esta última relación habría que especificar lo siguiente:

- No es cierto que cualquier `y` se corresponda con una `i`. Esto sólo es válido para el proceso de formación de plural que estamos considerando.
- En este caso concreto, la `y` se corresponde sólo con una `i`, y con ninguna otra letra, ni siquiera consigo misma.

El modelo de morfología de dos niveles incorpora un componente más que permite expresar este tipo de restricciones mediante reglas de transformación. Por ejemplo, esta relación *si y sólo si* podría denotarse mediante una regla de doble flecha como la siguiente:

```
y:i <=> _ -: e: s: ;
```

Un conjunto dado de reglas de este tipo se puede transformar en un traductor de estado finito [Karttunen y Beesley 1992]. Un *traductor de estado finito* no es más que un autómata finito que, en lugar de caracteres simples, incorpora correspondencias letra a letra como etiquetas de sus transiciones, permitiendo transformar la cadena superficial en la cadena teórica, y viceversa.

Ejemplo 2.12 La figura 2.10 representa un traductor de estado finito capaz de asociar cada una de las formas verbales del verbo `leave` con su lema y su correspondiente etiqueta, es decir: `leave` con `leave+VB`, `leaves` con `leave+VBZ` y `left` con `leave+VBD`[13]. □

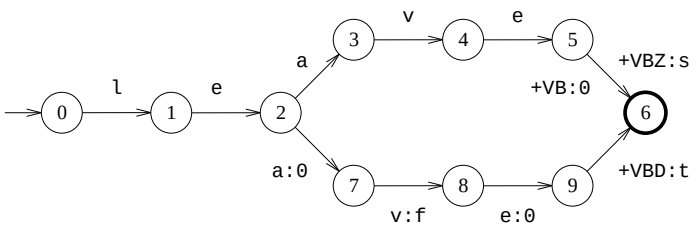

Figura 2.10: Traductor de estado finito para el verbo `leave`

Para cada palabra, existe en el traductor un camino que contiene la forma flexionada de la cadena superficial y el par lema-etiqueta de la cadena teórica. Dicho camino se puede encontrar utilizando como clave de entrada cualquiera de las dos cadenas. Esta característica de procesamiento bidireccional de los traductores finitos hace que el modelo de morfología de dos niveles resulte válido tanto para el análisis morfológico, como para la generación de formas.

Sin embargo, para los traductores, la noción de determinismo normalmente tiene sentido si se considera sólo una de las direcciones de aplicación. Si un traductor presenta este tipo de determinismo unidireccional, se dice que es o bien *secuencial por arriba*[14] si es determinista en la dirección de la cadena superficial, o bien *secuencial por abajo*[15] si es determinista en la dirección de la cadena teórica. Por ejemplo, el traductor de la figura 2.10 es secuencial por arriba, pero no secuencial por abajo, ya que desde el estado 2 con el símbolo de entrada `a` se puede transitar a dos estados diferentes, el 3 y el 7.

[13] La notación de las etiquetas es una adaptación del juego de etiquetas utilizado en el corpus BROWN [Francis y Kučera 1982]: `VB` significa verbo en infinitivo, `VBZ` es verbo en tercera persona del singular y `VBD` es verbo en tiempo pasado.

[14] *Sequential upward.*

[15] *Sequential downward.*

No obstante, al procesar una cadena dada, es probable que uno de los caminos termine con éxito y el otro no. Es decir, esta ambigüedad local podría ser resuelta algunas transiciones más tarde, y de hecho en este caso es así, ya que la relación que establece el traductor de la figura 2.10 es no ambigua en ambas direcciones. Si la relación es no ambigua en una dirección dada, y si todas las ambigüedades locales en esa dirección se pueden resolver a sí mismas en un número finito de pasos, se dice que el traductor es *secuenciable*, es decir, se puede construir un traductor secuencial equivalente en la misma dirección [Roche y Schabes 1995, Mohri 1995].

Ejemplo 2.13 La ambigüedad local del traductor de la figura 2.10 se resuelve en el estado 5. Por tanto, se puede incorporar un camino desde el estado inicial hasta el estado 5 que transforma la secuencia `ave` en la cadena vacía, lo cual, tal y como se muestra en la figura 2.11, permite construir un traductor secuencial por abajo, pero sólo en esa dirección, ya que ahora existen dos arcos con `a` en la cadena superior partiendo del estado 5. □

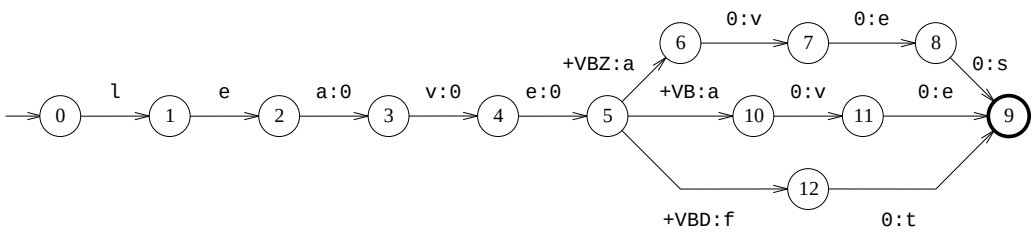

Figura 2.11: Traductor de estado finito secuencial por abajo para el verbo `leave`

Los traductores secuenciales se pueden extender para permitir que emitan desde los estados finales una cadena de salida adicional (*traductores subsecuenciales*) o un número finito p de cadenas de salida (*traductores p-subsecuenciales*). Estos últimos son los que permiten realizar el manejo de las ambigüedades léxicas presentes en los lenguajes naturales [Mohri 1995].

Y todos ellos, mediante la incorporación de una información numérica extra en cada estado, pueden pasar de ser simples conversores de una cadena en otra[16] a incorporar también la funcionalidad de conversión de una cadena en un peso numérico[17]. Típicamente, ese nuevo dato numérico podría ser una probabilidad logarítmica, de tal manera que la probabilidad de emisión de una palabra dada se calcularía simplemente sumando el dato de todos los estados por los que pasa el camino de procesamiento de dicha palabra en el traductor. Ésta es la forma de integrar probabilidades de emisión para las palabras en los traductores finitos [Mohri 1997].

De entre los múltiples trabajos basados en el modelo de Koskenniemi, destaca la herramienta MMORPH [Russell y Petitpierre 1995], un compilador de reglas morfológicas de dos niveles de libre distribución, desarrollado en el marco del proyecto MULTEXT[18].

Otros métodos de diseño de analizadores léxicos, que también han sido aplicados con éxito al idioma español, incluyen las aproximaciones basadas en unificación [Moreno 1991, Moreno y Goñi 1995, González Collar *et al.* 1995] y las basadas en árboles de decisión [Triviño 1995, Triviño y Morales 2000].

[16] Traductores *string-to-string*.

[17] Traductores *string-to-weight*.

[18] *Multilingual Text Tools and Corpora* es una iniciativa de la Comisión Europea (bajo los programas *Investigación e Ingeniería Lingüística*, *Copernicus*, y *Lenguas Regionales y Minoritarias*), de la Fundación Científica Nacional de los Estados Unidos, del Fondo Francófono para la Investigación, del CNRS (Centro Nacional francés para la Investigación Científica) y de la Universidad de Provenza. MULTEXT comprende una serie de proyectos cuyos objetivos son el desarrollo de estándares y especificaciones para la codificación y el procesamiento de textos, y para el desarrollo de herramientas, *corpora* y recursos lingüísticos bajo esos estándares. Los trabajos han sido realizados también en estrecha colaboración con los proyectos EAGLES y CRATER, e incluyen herramientas y recursos para la mayoría de los idiomas europeos.

Parte II

Sistemas de etiquetación tradicionales

Capítulo 3

Modelos de Markov ocultos (HMM,s)

Cuando se abordó inicialmente el problema de la etiquetación de textos en lenguaje natural, se comenzó diseñando manualmente reglas de etiquetación que intentaban describir el comportamiento del lenguaje humano. Sin embargo, en el momento en el que aparecen disponibles grandes cantidades de textos electrónicos, muchos de ellos incluso etiquetados, las aproximaciones estocásticas adquieren gran importancia en el proceso de etiquetación. Son muchas las ventajas de los etiquetadores estocásticos frente a los etiquetadores construidos manualmente. Además del hecho de que evitan la laboriosa construcción manual de las reglas, también capturan automáticamente información útil que el hombre podría no apreciar.

En este capítulo estudiaremos un método estocástico comúnmente denominado aproximación con modelos de Markov ocultos o HMM,s[1]. A pesar de sus limitaciones, los HMM,s y sus variantes son todavía la técnica más ampliamente utilizada en el proceso de etiquetación del lenguaje natural, y son generalmente referenciados como una de las técnicas más exitosas para dicha tarea. Los procesos de Markov fueron desarrollados inicialmente por Andrei A. Markov, alumno de Chebyshev, y su primera utilización tuvo un objetivo realmente lingüístico: modelizar las secuencias de letras de las palabras en la literatura rusa [Markov 1913]. Posteriormente, los modelos de Markov evolucionaron hasta convertirse en una herramienta estadística de propósito general. La suposición subyacente de las técnicas de etiquetación basadas en HMM,s es que la tarea de la etiquetación se puede formalizar como un proceso paramétrico aleatorio, cuyos parámetros se pueden estimar de una manera precisa y perfectamente definida.

Comenzaremos con un repaso de la teoría de cadenas de Markov, seguiremos con una extensión de las ideas mostradas hacia los modelos de Markov ocultos y centraremos nuestra atención en las tres cuestiones fundamentales que surgen a la hora de utilizar un HMM:

1. La evaluación de la probabilidad de una secuencia de observaciones, dado un HMM específico.

2. La determinación de la secuencia de estados más probable, dada una secuencia de observaciones específica.

3. La estimación de los parámetros del modelo para que éste se ajuste a las secuencias de observaciones disponibles.

Una vez que estos tres problemas fundamentales sean resueltos, veremos cómo se pueden aplicar inmediatamente los HMM,s al problema de la etiquetación del lenguaje natural, y estudiaremos con detalle las múltiples variantes de implementación que surgen al hacerlo.

[1] *Hidden Markov Models.*

3.1 Procesos de Markov de tiempo discreto

Consideremos un sistema que en cada instante de tiempo se encuentra en un determinado estado. Dicho estado pertenece a un conjunto finito de estados Q. De momento, para no complicar demasiado la notación, supondremos que existe una correspondencia entre el conjunto de estados Q y el conjunto de números enteros $\{1, 2, \ldots, N\}$, y etiquetaremos cada estado con uno de esos números, tal y como se ve en la figura 3.1, donde $N = 5$. Regularmente, transcurrido un espacio de tiempo discreto, el sistema cambia de estado (posiblemente volviendo al mismo), de acuerdo con un conjunto de probabilidades de transición asociadas a cada uno de los estados del modelo. Los instantes de tiempo asociados a cada cambio de estado se denotan como $t = 1, 2, \ldots, T$, y el estado actual en el instante de tiempo t se denota como q_t. En general, una descripción probabilística completa del sistema requeriría la especificación del estado actual, así como de todos los estados precedentes. Sin embargo, las cadenas de Markov presentan dos características muy importantes:

1. **Propiedad del horizonte limitado**. Esta propiedad permite truncar la dependencia probabilística del estado actual y considerar, no todos los estados precedentes, sino únicamente un subconjunto finito de ellos. En general, una cadena de Markov de orden n es la que utiliza n estados previos para predecir el siguiente estado. Por ejemplo, para el caso de las cadenas de Markov de tiempo discreto de primer orden tenemos que:

$$P(q_t = j | q_{t-1} = i, q_{t-2} = k, \ldots) = P(q_t = j | q_{t-1} = i). \tag{3.1}$$

2. **Propiedad del tiempo estacionario**. Esta propiedad nos permite considerar sólo aquellos procesos en los cuales la parte derecha de (3.1) es independiente del tiempo. Esto nos lleva a una matriz $A = \{a_{ij}\}$ de probabilidades de transición entre estados de la forma

$$a_{ij} = P(q_t = j | q_{t-1} = i) = P(j|i), \qquad 1 \leq i, j \leq N,$$

independientes del tiempo, pero con las restricciones estocásticas estándar:

$$a_{ij} \geq 0, \qquad \forall i, j,$$

$$\sum_{j=1}^{N} a_{ij} = 1, \qquad \forall i.$$

Sin embargo, es necesario especificar también el vector $\pi = \{\pi_i\}$, que almacena la probabilidad que tiene cada uno de los estados de ser el estado inicial[2]:

$$\pi_i = P(q_1 = i), \qquad \pi_i \geq 0, \qquad 1 \leq i \leq N,$$

$$\sum_{i=1}^{N} \pi_i = 1.$$

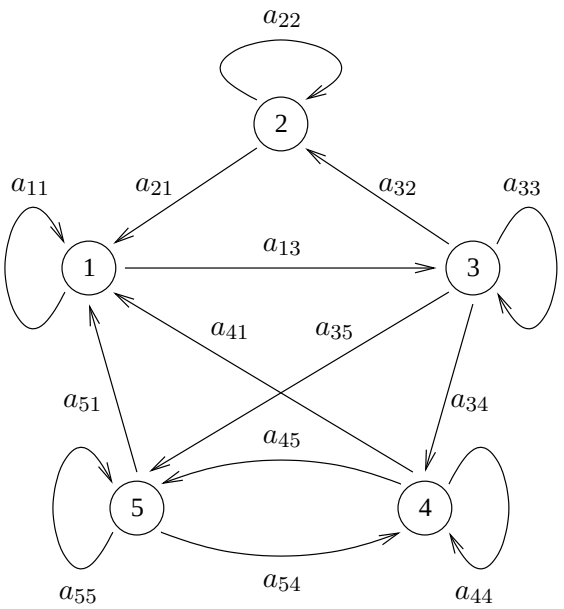

Figura 3.1: Una cadena de Markov de 5 estados con algunas transiciones entre ellos

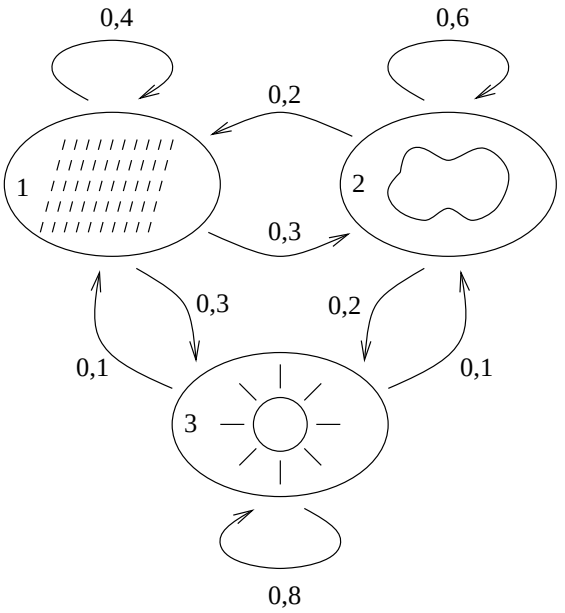

Figura 3.2: Un modelo de Markov para la evolución del clima

A un proceso estocástico que satisface estas características se le puede llamar un *modelo de Markov observable*, porque su salida es el conjunto de estados por los que pasa en cada instante de tiempo, y cada uno de estos estados se corresponde con un suceso observable.

Ejemplo 3.1 Para remarcar las ideas, supongamos que una vez al día, por ejemplo al mediodía, se observa el clima, y las posibles observaciones resultan ser las siguientes: (1) precipitación de lluvia o nieve, (2) nublado, o (3) soleado. Supongamos también que el clima del día t se caracteriza por uno solo de esos tres estados, que la matriz A de las probabilidades de transición entre estados es

$$A = \{a_{ij}\} = \begin{bmatrix} 0,4 & 0,3 & 0,3 \\ 0,2 & 0,6 & 0,2 \\ 0,1 & 0,1 & 0,8 \end{bmatrix}$$

y que los tres estados tienen la misma probabilidad de ser el estado inicial, es decir, $\pi_i = \frac{1}{3}$, $1 \leq i \leq 3$. Tal y como se ve en la figura 3.2, no hemos hecho más que especificar un modelo de Markov para describir la evolución del clima. □

La probabilidad de observar una determinada secuencia de estados, es decir, la probabilidad de que una secuencia finita de T variables aleatorias con dependencia de primer orden, $q_1, q_2, \ldots, q_T$, tome unos determinados valores, $o_1, o_2, \ldots, o_T$, con todos los $o_i \in \{1, 2, \ldots, N\}$, es sencilla de obtener. Simplemente calculamos el producto de las probabilidades que figuran en las aristas del grafo o en la matriz de transiciones:

$$P(o_1, o_2, \ldots, o_T) =$$

$$= P(q_1 = o_1)P(q_2 = o_2|q_1 = o_1)P(q_3 = o_3|q_2 = o_2)\ldots P(q_T = o_T|q_{T-1} = o_{T-1}) =$$

[2]La necesidad de este vector podría evitarse especificando que la cadena de Markov comienza siempre en un estado inicial extra, e incluyendo en la matriz A las probabilidades de transición de este nuevo estado: las del vector π para aquellas celdas que lo tienen como estado origen, y 0 para las que lo tienen como estado destino.

$$= \pi_{o_1} \prod_{t=1}^{T-1} a_{o_t o_{t+1}}.$$

Ejemplo 3.2 Utilizando el modelo de Markov para la evolución del clima, podemos calcular la probabilidad de observar la secuencia de estados 2, 3, 2, 1, como sigue:

$$P(2,3,2,1) = P(2)P(3|2)P(2|3)P(1|2) = \pi_2 \times a_{23} \times a_{32} \times a_{21} = \frac{1}{3} \times 0,2 \times 0,1 \times 0,2 = 0,00133333.$$

Ésta es, por tanto, la probabilidad que corresponde a la secuencia *nublado-soleado-nublado-lluvia.* □

3.2 Extensión a modelos de Markov ocultos

En la sección anterior hemos considerado modelos de Markov en los cuales cada estado se corresponde de manera determinista con un único suceso observable. Es decir, la salida en un estado dado no es aleatoria, sino que es siempre la misma. Esta modelización puede resultar demasiado restrictiva a la hora de ser aplicada a problemas reales. En esta sección extendemos el concepto de modelos de Markov de tal manera que es posible incluir aquellos casos en los cuales la observación es una función probabilística del estado. El modelo resultante, denominado modelo de Markov oculto, es un modelo doblemente estocástico, ya que uno de los procesos no se puede observar directamente (está oculto), sino que se puede observar sólo a través de otro conjunto de procesos estocásticos, los cuales producen la secuencia de observaciones.

Ejemplo 3.3 Para ilustrar los conceptos básicos de un modelo de Markov oculto consideremos el sistema de urnas y bolas de la figura 3.3. El modelo consta de un gran número N de urnas colocadas dentro de una habitación. Cada urna contiene en su interior un número también grande de bolas. Cada bola tiene un único color, y el número de colores distintos para ellas es M. El proceso físico para obtener las observaciones es como sigue. Una persona se encuentra dentro de la habitación y, siguiendo un procedimiento totalmente aleatorio, elige una urna inicial, saca una bola, nos grita en alto su color y devuelve la bola a la urna. Posteriormente elige otra urna de acuerdo con un proceso de selección aleatorio asociado a la urna actual, y efectúa la extracción de una nueva bola. Este paso se repite un determinado número de veces, de manera que todo el proceso genera una secuencia finita de colores, la cual constituye la salida observable del modelo, quedando oculta para nosotros la secuencia de urnas que se ha seguido.

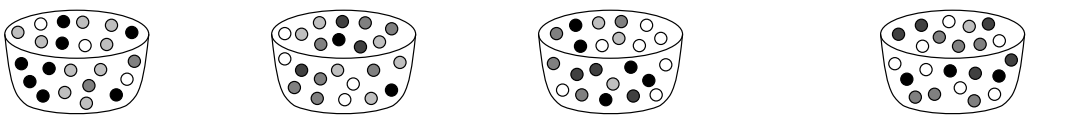

Urna 1	Urna 2	Urna 3		Urna N
$P(color\ 1) = b_{11}$	$P(color\ 1) = b_{21}$	$P(color\ 1) = b_{31}$	...	$P(color\ 1) = b_{N1}$
$P(color\ 2) = b_{12}$	$P(color\ 2) = b_{22}$	$P(color\ 2) = b_{32}$	...	$P(color\ 2) = b_{N2}$
$P(color\ 3) = b_{13}$	$P(color\ 3) = b_{23}$	$P(color\ 3) = b_{33}$	...	$P(color\ 3) = b_{N3}$
$\vdots$	$\vdots$	$\vdots$		$\vdots$
$P(color\ M) = b_{1M}$	$P(color\ M) = b_{2M}$	$P(color\ M) = b_{3M}$	...	$P(color\ M) = b_{NM}$

Figura 3.3: Un modelo de Markov oculto de N urnas de bolas y M colores

Este proceso se modeliza de forma que cada urna se corresponde con un estado del HMM, la elección de las urnas se realiza de acuerdo con la matriz de probabilidades de transición entre

estados asociada al modelo, y para cada uno de esos estados existe una función de probabilidad de los colores perfectamente definida. Es importante señalar también que lo que hace que una urna sea distinta de otra es la cantidad de bolas de cada color que tiene en su interior, pero los colores de las bolas son los mismos para todas las urnas. Por tanto, una observación aislada de un determinado color de bola no nos dice automáticamente de qué urna viene esa bola. □

El ejemplo de las urnas y las bolas puede identificarse de una manera muy intuituva con el problema de la etiquetación de las palabras de un texto en lenguaje natural. En este caso concreto, las bolas representan a las palabras, las urnas representan a las distintas etiquetas o categorías gramaticales a las que pertenecen las palabras, y las secuencias de observaciones representan a las frases del texto. Una misma palabra puede estar en urnas distintas, de ahí la ambigüedad léxica, y puede estar también varias veces en la misma urna, de ahí que las probabilidades de las palabras que están dentro de una misma urna puedan ser distintas.

3.3 Elementos de un modelo de Markov oculto

Los ejemplos vistos anteriormente nos proporcionan una idea de lo que son los modelos de Markov ocultos y de cómo se pueden aplicar a escenarios prácticos reales, tales como la etiquetación de las palabras de un texto en lenguaje natural. Pero antes de tratar nuestro caso particular, vamos a definir formalmente cuáles son los elementos de un modelo de Markov oculto.

Definición 3.1 Un *HMM* se caracteriza por la 5-tupla (Q, V, π, A, B), donde:

1. Q es el conjunto de estados del modelo. Aunque los estados permanecen ocultos, para la mayoría de las aplicaciones prácticas se conocen *a priori*. Por ejemplo, para el caso de la etiquetación de palabras, cada etiqueta del juego de etiquetas utilizado sería un estado. Generalmente los estados están conectados de tal manera que cualquiera de ellos se puede alcanzar desde cualquier otro en un solo paso, aunque existen muchas otras posibilidades de interconexión. Los estados se etiquetan como $\{1, 2, \ldots, N\}$, y el estado actual en el instante de tiempo t se denota como q_t. El uso de instantes de tiempo es apropiado, por ejemplo, en la aplicación de los HMM,s al procesamiento de voz. No obstante, para el caso de la etiquetación de palabras, no hablaremos de los instantes de tiempo, sino de las posiciones de cada palabra dentro de la frase.

2. V es el conjunto de los distintos sucesos que se pueden observar en cada uno de los estados. Por tanto, cada uno de los símbolos individuales que un estado puede emitir se denota como $\{v_1, v_2, \ldots, v_M\}$. En el caso del modelo de las urnas y las bolas, M es el número de colores distintos y cada $v_k, 1 \leq k \leq M$, es un color distinto. En el caso de la etiquetación de palabras, M es el tamaño del diccionario y cada $v_k, 1 \leq k \leq M$, es una palabra distinta.

3. $\pi = \{\pi_i\}$, es la distribución de probabilidad del estado inicial. Por tanto,

$$\pi_i = P(q_1 = i), \qquad \pi_i \geq 0, \qquad 1 \leq i \leq N,$$

$$\sum_{i=1}^{N} \pi_i = 1.$$

4. $A = \{a_{ij}\}$ es la distribución de probabilidad de las transiciones entre estados, es decir,

$$a_{ij} = P(q_t = j | q_{t-1} = i) = P(j|i), \qquad 1 \leq i, j \leq N, \qquad 1 \leq t \leq T,$$

$$\sum_{j=1}^{N} a_{ij} = 1, \qquad \forall i.$$

Para el caso de un modelo con estados totalmente conexos en un solo paso, tenemos que $a_{ij} > 0$ para todo i, j. Para otro tipo de HMM,s podría existir algún $a_{ij} = 0$.

5. $B = \{b_j(v_k)\}$ es la distribución de probabilidad de los sucesos observables, es decir,

$$b_j(v_k) = P(o_t = v_k | q_t = j) = P(v_k|j), \quad b_j(v_k) \geq 0, \quad 1 \leq j \leq N,\ 1 \leq k \leq M,\ 1 \leq t \leq T.$$

$$\sum_{k=1}^{M} b_j(v_k) = 1, \qquad \forall j.$$

Este conjunto de probabilidades se conoce también con el nombre de *conjunto de probabilidades de emisión*.

Tal y como hemos visto, una descripción estricta de un HMM necesita la especificación de Q y V, el conjunto de estados y el conjunto de los símbolos que forman las secuencias de observación, respectivamente, y la especificación de los tres conjuntos de probabilidades π, A y B. Pero dado que los dos primeros conjuntos normalmente se conocen *a priori*, y que en todo caso los tres últimos elementos del HMM ya incluyen de manera explícita al resto de los parámetros, utilizaremos la notación compacta

$$\mu = (\pi, A, B)$$

a lo largo de las siguientes secciones, y ésta seguirá siendo una representación completa de un HMM. □

Dada una especificación de un HMM, podemos simular un proceso estocástico que genere secuencias de datos, donde las leyes de producción de dichas secuencias están perfectamente definidas en el modelo. Sin embargo, es mucho más interesante tomar una secuencia de datos, suponer que efectivamente ha sido generada por un HMM, y estudiar distintas propiedades sobre ella, tales como su probabilidad, o la secuencia de estados más probable por la que ha pasado. La siguiente sección se ocupa de este tipo de cuestiones.

3.4 Las tres preguntas fundamentales al usar un HMM

Existen tres preguntas fundamentales que debemos saber responder para poder utilizar los HMM,s en aplicaciones reales. Estas tres preguntas son las siguientes:

1. Dada una secuencia de observaciones $O = (o_1, o_2, \ldots, o_T)$ y dado un modelo $\mu = (\pi, A, B)$, ¿cómo calculamos de una manera eficiente $P(O|\mu)$, es decir, la probabilidad de dicha secuencia dado el modelo?

2. Dada una secuencia de observaciones $O = (o_1, o_2, \ldots, o_T)$ y dado un modelo $\mu = (\pi, A, B)$, ¿cómo elegimos la secuencia de estados $S = (q_1, q_2, \ldots, q_T)$ óptima, es decir, la que mejor *explica* la secuencia de observaciones?

3. Dada una secuencia de observaciones $O = (o_1, o_2, \ldots, o_T)$, ¿cómo estimamos los parámetros del modelo $\mu = (\pi, A, B)$ para maximizar $P(O|\mu)$?, es decir, ¿cómo podemos encontrar el modelo que mejor *explica* los datos observados?

Normalmente, los problemas que manejaremos en la práctica no son tan sencillos como el modelo de las urnas y las bolas, es decir, lo normal es que no conozcamos *a priori* los parámetros del modelo y tengamos que estimarlos a partir de los datos observados. La secuencia de observación utilizada para ajustar los parámetros del modelo se denomina secuencia de *entrenamiento*, ya que a partir de ella se entrena el HMM. Ésta es la problemática que se aborda en la tercera pregunta.

La segunda pregunta trata el problema de descubrir la parte oculta del modelo, es decir, trata sobre cómo podemos adivinar qué camino ha seguido la cadena de Markov. Este camino oculto se puede utilizar para clasificar las observaciones. En el caso de la etiquetación de un texto en lenguaje natural, dicho camino nos ofrece la secuencia de etiquetas más probable para las palabras del texto.

La primera pregunta representa el problema de la evaluación de una secuencia de observaciones dado el modelo. La resolución de este problema nos proporciona la probabilidad de que la secuencia haya sido generada por ese modelo. Un ejemplo práctico puede ser suponer la existencia de varios HMM,s compitiendo entre sí. La evaluación de la secuencia en cada uno de ellos nos permitirá elegir el modelo que mejor encaja con los datos observados.

A continuación se describen formalmente todos los algoritmos matemáticos que son necesarios para responder a estas tres preguntas.

3.4.1 Cálculo de la probabilidad de una observación

Dada una secuencia de observaciones $O = (o_1, o_2, \ldots, o_T)$ y un modelo $\mu = (\pi, A, B)$, queremos calcular de una manera eficiente $P(O|\mu)$, es decir, la probabilidad de dicha secuencia dado el modelo. La forma más directa de hacerlo es enumerando primero todas las posibles secuencias de estados de longitud T, el número de observaciones. Existen N^T secuencias distintas. Considerando una de esas secuencias, $S = (q_1, q_2, \ldots, q_T)$, la probabilidad de dicha secuencia de estados es

$$P(S|\mu) = \pi_{q_1}\, a_{q_1 q_2}\, a_{q_2 q_3} \ldots a_{q_{T-1} q_T} \tag{3.2}$$

y la probabilidad de observar O a través de la secuencia S es

$$P(O|S,\mu) = \prod_{t=1}^{T} P(o_t|q_t,\mu) = b_{q_1}(o_1)\, b_{q_2}(o_2) \ldots b_{q_T}(o_T) \tag{3.3}$$

La probabilidad conjunta de O y S, es decir, la probabilidad de que O y S ocurran simultáneamente, es simplemente el producto de (3.2) y (3.3), es decir,

$$P(O,S|\mu) = P(S|\mu)\, P(O|S,\mu)$$

Por tanto, la probabilidad de O dado el modelo se obtiene sumando esta probabilidad conjunta para todas las posibles secuencias S:

$$P(O|\mu) = \sum_{S} P(S|\mu)\, P(O|S,\mu).$$

Sin embargo, si calculamos $P(O|\mu)$ de esta forma, necesitamos realizar exactamente $(2T-1)N^T$ multiplicaciones y $N^T - 1$ sumas, es decir, un total de $2TN^T - 1$ operaciones. Estas cifras no son computacionalmente admisibles ni siquiera para valores pequeños de N y T. Por ejemplo, para $N = 5$ estados y $T = 100$ observaciones, el número de operaciones es del orden de 10^{72}. El secreto para evitar esta complejidad tan elevada está en utilizar técnicas de programación dinámica, con el fin de recordar los resultados parciales, en lugar de recalcularlos. A continuación se presentan varios procedimientos que calculan $P(O|\mu)$ utilizando dichas técnicas.

3.4.1.1 Procedimiento hacia adelante

Consideremos la variable $\alpha_t(i)$ definida como

$$\alpha_t(i) = P(o_1, o_2, \ldots, o_t, q_t = i|\mu),$$

es decir, la probabilidad conjunta de obtener $o_1, o_2, \ldots, o_t$, la secuencia parcial de observaciones hasta el instante de tiempo t, y de estar en el estado i en ese instante de tiempo t, dado el modelo μ. Los valores de $\alpha_t(i)$, para los distintos estados y para los distintos instantes de tiempo, se pueden obtener iterativamente, y pueden ser utilizados para calcular $P(O|\mu)$ mediante los pasos del siguiente algoritmo.

Algoritmo 3.1 Cálculo hacia adelante de la probabilidad de una secuencia de observaciones:

1. Inicialización:
$$\alpha_1(i) = \pi_i \, b_i(o_1), \qquad 1 \leq i \leq N.$$

2. Recurrencia:
$$\alpha_{t+1}(j) = \left[\sum_{i=1}^{N} \alpha_t(i) \, a_{ij}\right] b_j(o_{t+1}), \qquad t = 1, 2, \ldots, T-1, \qquad 1 \leq j \leq N. \tag{3.4}$$

3. Terminación:
$$P(O|\mu) = \sum_{i=1}^{N} \alpha_T(i).$$

El paso 1 inicializa las N probabilidades $\alpha_1(i)$ como la probabilidad conjunta de que i sea el estado inicial y genere la primera observación o_1. El paso de recurrencia, que es el punto central de este algoritmo, se ilustra en la figura 3.4 (a). Esta figura muestra cómo el estado j se puede alcanzar en el instante de tiempo $t+1$ desde los N posibles estados i del instante de tiempo t. Para cada uno de esos estados, dado que $\alpha_t(i)$ es la probabilidad conjunta de haber observado $o_1, o_2, \ldots, o_t$, y de estar en el estado i en el instante t, $\alpha_t(i) \, a_{ij}$ será la probabilidad conjunta de haber observado $o_1, o_2, \ldots, o_t$, y de haber alcanzado el estado j en el instante $t+1$ desde el estado i del instante t. Sumando todos estos productos sobre los N posibles estados i del instante t, y multiplicando esa suma por $b_j(o_{t+1})$, la probabilidad de que el estado j emita el símbolo o_{t+1}, obtenemos $\alpha_{t+1}(j)$, es decir, la probabilidad conjunta de obtener $o_1, o_2, \ldots, o_{t+1}$, la secuencia parcial de observaciones hasta el instante de tiempo $t+1$, y de estar en el estado j en ese instante de tiempo $t+1$. El cálculo de la ecuación (3.4) se realiza para los N estados j de un mismo instante de tiempo t, y para todos los instantes de tiempo $t = 1, 2, \ldots, T-1$. Finalmente, el paso 3 obtiene $P(O|\mu)$ sumando el valor de las N variables $\alpha_T(i)$. □

Los cálculos globales involucrados en este proceso requieren del orden de N^2T operaciones, tal y como se muestra en el enrejado de la figura 3.4 (b). Más concretamente, se trata de $N(N+1)(T-1) + N$ multiplicaciones y $N(N-1)(T-1) + N - 1$ sumas, es decir, un total de $2(T-1)N^2 + 2N - 1$ operaciones. Para $N = 5$ estados y $T = 100$ observaciones, el número total de operaciones es aproximadamente 5.000, que comparado con 10^{72} supone un ahorro de 69 órdenes de magnitud.

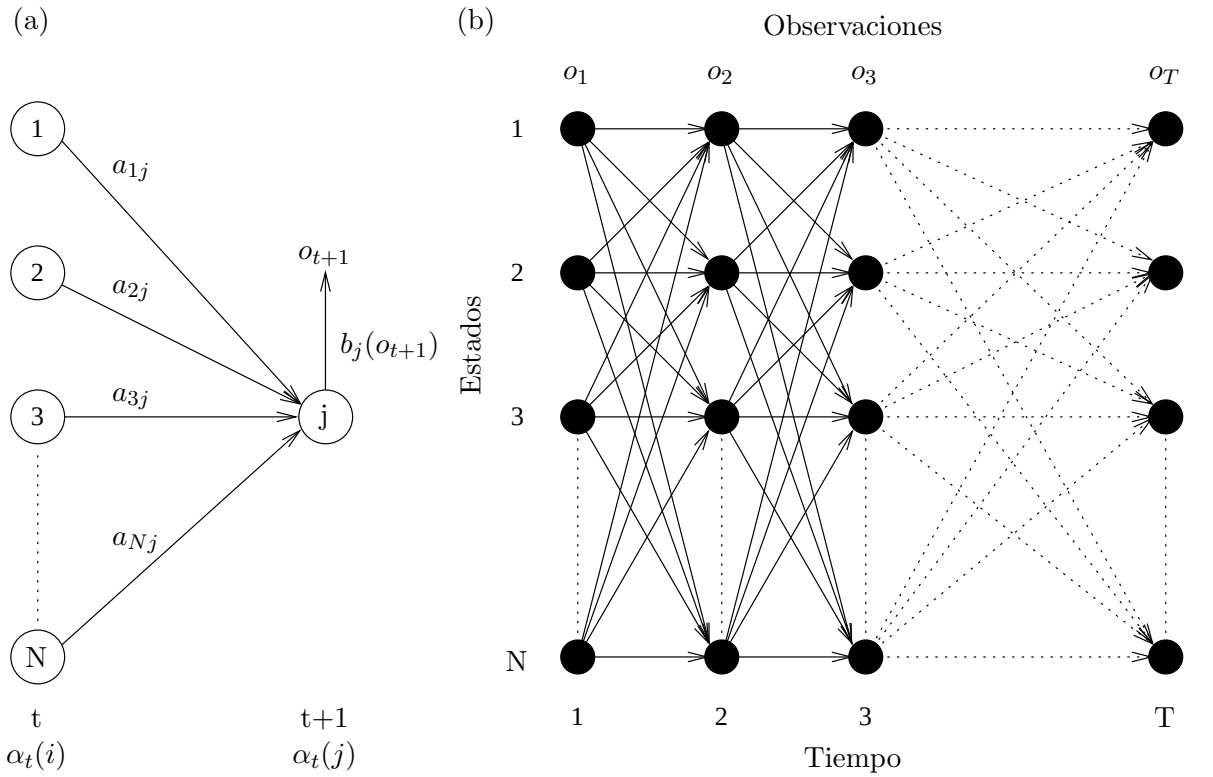

Figura 3.4: (a) Detalle de la secuencia de operaciones necesarias para el cálculo hacia adelante de la variable $\alpha_{t+1}(j)$ y (b) implementación genérica del cálculo hacia adelante de la variable $\alpha_t(i)$ mediante un enrejado de T observaciones y N estados

3.4.1.2 Procedimiento hacia atrás

De manera similar, podemos considerar la variable $\beta_t(i)$ definida como

$$\beta_t(i) = P(o_{t+1}, o_{t+2}, \ldots, o_T | q_t = i, \mu),$$

es decir, la probabilidad de la secuencia de observación parcial desde el instante de tiempo $t+1$ hasta el final, dado que el estado en el instante de tiempo t es i y dado el modelo μ. Nuevamente, podemos resolver las variables $\beta_t(i)$ y calcular el valor de $P(O|\mu)$ de manera recurrente mediante los pasos del siguiente algoritmo.

Algoritmo 3.2 Cálculo hacia atrás de la probabilidad de una secuencia de observaciones:

1. Inicialización:
$$\beta_T(i) = 1, \qquad 1 \leq i \leq N.$$

2. Recurrencia:
$$\beta_t(i) = \sum_{j=1}^{N} a_{ij}\, \beta_{t+1}(j)\, b_j(o_{t+1}), \qquad t = T-1, T-2, \ldots, 1, \qquad 1 \leq i \leq N.$$

3. Terminación:
$$P(O|\mu) = \sum_{i=1}^{N} \beta_1(i)\, \pi_i\, b_i(o_1).$$

El paso de inicialización asigna 1 a las N variables $\beta_T(i)$. El paso de recurrencia, tal y como se muestra en la figura 3.5, calcula el valor de $\beta_t(i)$ en función de las N variables $\beta_{t+1}(j)$ del instante siguiente, en función de las probabilidades de transición entre estados a_{ij}, y en función de las probabilidades de emisión del símbolo o_{t+1} desde los N estados j. Finalmente, el paso 3 obtiene $P(O|\mu)$ sumando el valor de las N variables $\beta_1(i)$ multiplicado por la probabilidad de que el estado i sea el estado inicial y por la probabilidad de que emita el primer símbolo de observación o_1. □

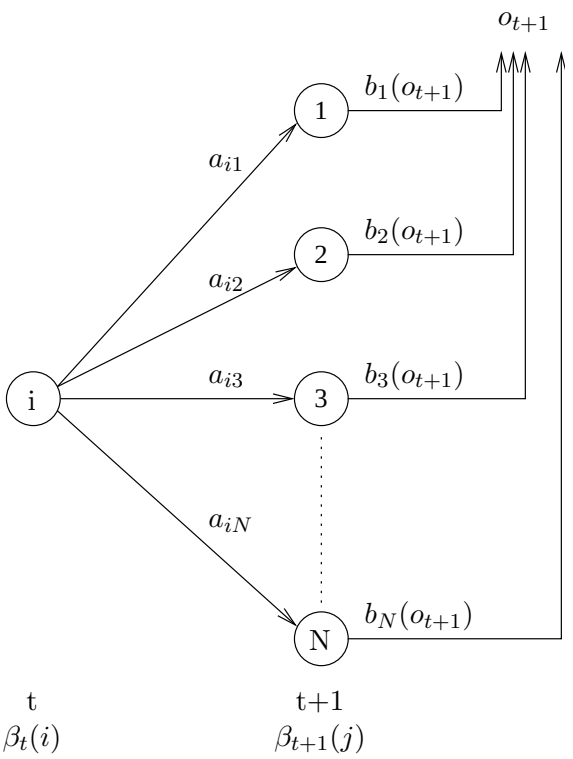

Figura 3.5: Detalle de la secuencia de operaciones necesarias para el cálculo hacia atrás de $\beta_t(i)$

Una vez más, el cálculo de las variables $\beta_t(i), 1 \leq t \leq T, 1 \leq i \leq N$, requiere del orden de N^2T operaciones y se puede resolver sobre un enrejado similar al de la figura 3.4 (b). Por tanto, la verdadera razón para haber introducido este procedimiento hacia atrás es que los cálculos involucrados en él son de vital importancia para resolver las preguntas fundamentales 2 y 3 sobre los HMM,s, es decir, el cálculo de la secuencia de estados óptima y la estimación de los parámetros del modelo, tal y como veremos a continuación.

3.4.2 Elección de la secuencia de estados más probable

El segundo problema ha sido definido vagamente como el problema de encontrar la secuencia de estados óptima que mejor *explica* las observaciones. Debido a esta definición informal del problema, podrían existir varias formas de abordarlo, es decir, se podrían considerar diferentes criterios para esa optimación. Uno de ellos podría ser la elección de los estados que son *individualmente* más probables en cada instante de tiempo. Para implementar este criterio, podemos considerar la cantidad $\gamma_t(i)$ definida como

$$\gamma_t(i) = P(q_t = i|O, \mu), \tag{3.5}$$

es decir, la probabilidad de estar en el estado i en el instante t, dada la secuencia de obsevaciones O y dado el modelo μ. Dicha cantidad se puede obtener a partir de

$$\gamma_t(i) = P(q_t = i|O,\mu) = \frac{P(q_t = i, O|\mu)}{P(O|\mu)} = \frac{P(q_t = i, O|\mu)}{\sum_{j=1}^{N} P(q_t = j, O|\mu)} = \frac{\alpha_t(i)\,\beta_t(i)}{\sum_{j=1}^{N} \alpha_t(j)\,\beta_t(j)} \tag{3.6}$$

donde $\alpha_t(i)$ almacena la probabilidad de la observación parcial $o_1, o_2, \ldots, o_t$, y $\beta_t(i)$ almacena la probabilidad de la observación parcial $o_{t+1}, o_{t+2}, \ldots, o_T$, dado el estado i en el instante t. Utilizando $\gamma_t(i)$ podemos obtener q_t^*, el estado individualmente más probable en el instante t, como

$$q_t^* = \arg \max_{1 \le i \le N} [\gamma_t(i)], \qquad 1 \le t \le T. \tag{3.7}$$

La ecuación (3.7) maximiza el número esperado de estados correctos, eligiendo el estado más probable en cada instante t. Sin embargo, podrían surgir problemas con la secuencia de estados resultante. Por ejemplo, en un HMM con alguna transición entre estados de probabilidad cero ($a_{ij} = 0$ para algún i y algún j), podría ocurrir que esos estados i y j aparecieran contiguos en la secuencia óptima, cuando de hecho esa secuencia ni siquiera sería una secuencia válida. Esto es debido a que la solución que nos proporciona la ecuación (3.7) determina simplemente el estado más probable en cada instante, sin tener en cuenta la probabilidad de la secuencia de estados resultante.

Una posible solución al problema anterior es modificar el criterio de optimalidad para considerar, por ejemplo, la secuencia que maximiza el número esperado de pares de estados correctos (q_{t-1}, q_t), o de triplas de estados correctos (q_{t-2}, q_{t-1}, q_t), etc. Aunque estos criterios podrían ser razonables para algunas aplicaciones, el criterio más ampliamente utilizado consiste en encontrar la mejor secuencia considerando globalmente todos los instantes de tiempo, es decir, la secuencia de estados $S = (q_1, q_2, \ldots, q_T)$ que maximiza $P(S|O,\mu)$, lo cual es equivalente a maximizar $P(S, O|\mu)$. Existe un procedimiento formal y eficiente, basado también en técnicas de programación dinámica, para obtener esa secuencia S. Dicho procedimiento es el algoritmo de Viterbi [Viterbi 1967, Forney 1973].

3.4.2.1 Algoritmo de Viterbi

Para encontrar la secuencia de estados más probable, $S = (q_1, q_2, \ldots, q_T)$, dada la observación $O = (o_1, o_2, \ldots, o_T)$, consideramos la variable $\delta_t(i)$ definida como

$$\delta_t(i) = \max_{q_1, q_2, \ldots, q_{t-1}} P(q_1, q_2, \ldots, q_{t-1}, q_t = i, o_1, o_2, \ldots, o_t|\mu),$$

es decir, $\delta_t(i)$ almacena la probabilidad del mejor camino que termina en el estado i, teniendo en cuenta las t primeras observaciones. Se demuestra fácilmente que

$$\delta_{t+1}(j) = \left[\max_{1 \le i \le N} \delta_t(i)\, a_{ij}\right] b_j(o_{t+1}). \tag{3.8}$$

Una vez calculadas las $\delta_t(i)$ para todos los estados y para todos los instantes de tiempo, la secuencia de estados se construye realmente hacia atrás a través de una traza que recuerda el argumento que maximizó la ecuación (3.8) para cada instante t y para cada estado j. Esta traza se almacena en las correspondientes variables $\psi_t(j)$. La descripción completa del algoritmo es como sigue.

Algoritmo 3.3 Cálculo de la secuencia de estados más probable para una secuencia de observaciones dada (algoritmo de Viterbi):

1. Inicialización:
$$\delta_1(i) = \pi_i \, b_i(o_1), \qquad 1 \leq i \leq N.$$

2. Recurrencia:
$$\delta_{t+1}(j) = \left[\max_{1 \leq i \leq N} \delta_t(i) \, a_{ij} \right] b_j(o_{t+1}), \qquad t = 1, 2, \ldots, T-1, \qquad 1 \leq j \leq N. \tag{3.9}$$

$$\psi_{t+1}(j) = \arg \max_{1 \leq i \leq N} \delta_t(i) \, a_{ij}, \qquad t = 1, 2, \ldots, T-1, \qquad 1 \leq j \leq N.$$

3. Terminación:
$$q_T^* = \arg \max_{1 \leq i \leq N} \delta_T(i).$$

4. Construcción hacia atrás de la secuencia de estados:
$$q_t^* = \psi_{t+1}(q_{t+1}^*), \qquad t = T-1, T-2, \ldots, 1.$$

El algoritmo de Viterbi es similar al cálculo hacia adelante de la probabilidad de una observación que vimos en el algoritmo 3.1. Las únicas diferencias reseñables son que el sumatorio de la ecuación (3.4) se ha cambiado por la maximización de la ecuación (3.9), y que se ha añadido el paso final para construir hacia atrás la secuencia de estados. En todo caso, la complejidad del algoritmo es del orden de N^2T operaciones y se puede resolver también sobre un enrejado similar al de la figura 3.4 (b). □

Por supuesto, durante los cálculos del algoritmo de Viterbi se podrían obtener empates. Si esto ocurre, la elección del camino se realizaría aleatoriamente. Por otra parte, existen a menudo aplicaciones prácticas en las cuales se utiliza no sólo la mejor secuencia de estados, sino las n mejores secuencias. Para todos estos casos, se podría considerar una implementación del algoritmo de Viterbi que devolviera varias secuencias de estados.

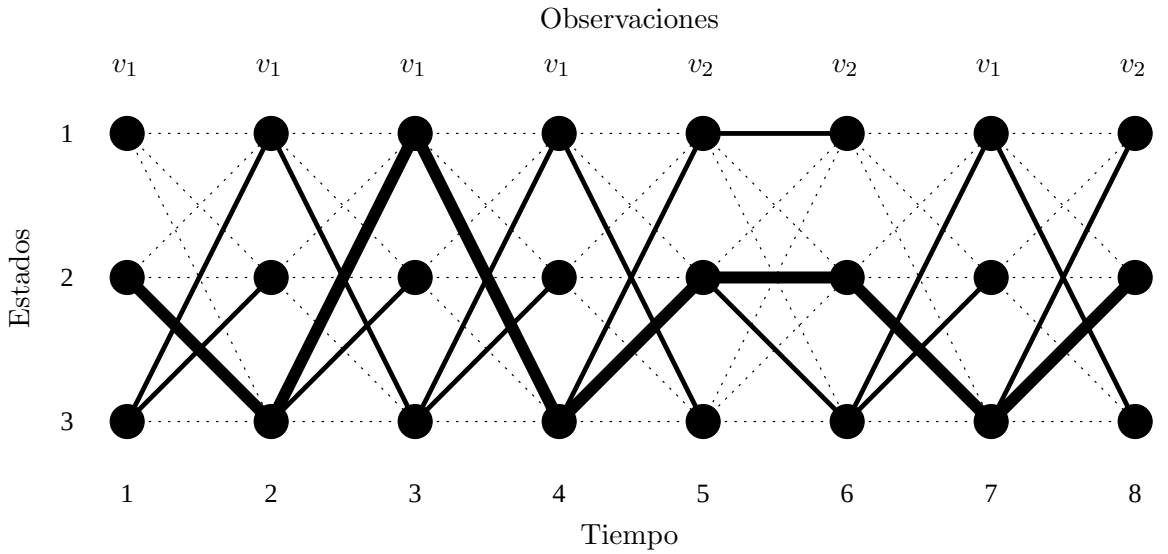

Figura 3.6: Ejemplo de ejecución del algoritmo de Viterbi

Ejemplo 3.4 A continuación presentamos un ejemplo de ejecución del algoritmo de Viterbi. Supongamos un HMM con tres estados y dos símbolos de observación, $\mu = (Q, V, \pi, A, B)$, donde

$$Q = \{1, 2, 3\}, \qquad V = \{v_1, v_2\}, \qquad \pi = \begin{bmatrix} 0,25 \\ 0,50 \\ 0,25 \end{bmatrix},$$

$$A = \begin{bmatrix} 0,25 & 0,25 & 0,50 \\ 0 & 0,25 & 0,75 \\ 0,50 & 0,50 & 0 \end{bmatrix} \quad y \quad B = \begin{bmatrix} 0,50 & 0,50 \\ 0,25 & 0,75 \\ 0,75 & 0,25 \end{bmatrix}.$$

Los cálculos para encontrar la secuencia de estados más probable dada la observación

$$O = (v_1, v_1, v_1, v_1, v_2, v_2, v_1, v_2)$$

de longitud $T = 8$, son los siguientes:

$$\begin{aligned}
&\delta_1(1) = \pi_1\, b_1(v_1) = (0,25)(0,50) \\
&\delta_1(2) = \pi_2\, b_2(v_1) = (0,50)(0,25) \\
&\delta_1(3) = \pi_3\, b_3(v_1) = (0,25)(0,75)
\end{aligned}$$

$$\begin{aligned}
&\delta_2(1) = \max\left[\delta_1(1)\,a_{11}, \delta_1(2)\,a_{21}, \underline{\delta_1(3)\,a_{31}}\right] b_1(v_1) = (0,25)\,(0,50)^2\,(0,75) \qquad \psi_2(1) = 3 \\
&\delta_2(2) = \max\left[\delta_1(1)\,a_{12}, \delta_1(2)\,a_{22}, \underline{\delta_1(3)\,a_{32}}\right] b_2(v_1) = (0,25)^2\,(0,50)\,(0,75) \qquad \psi_2(2) = 3 \\
&\delta_2(3) = \max\left[\delta_1(1)\,a_{13}, \underline{\delta_1(2)\,a_{23}}, \delta_1(3)\,a_{33}\right] b_3(v_1) = (0,25)\,(0,50)\,(0,75)^2 \qquad \psi_2(3) = 2
\end{aligned}$$

$$\begin{aligned}
&\delta_3(1) = \max\left[\delta_2(1)\,a_{11}, \delta_2(2)\,a_{21}, \underline{\delta_2(3)\,a_{31}}\right] b_1(v_1) = (0,25)\,(0,50)^3\,(0,75)^2 \qquad \psi_3(1) = 3 \\
&\delta_3(2) = \max\left[\delta_2(1)\,a_{12}, \delta_2(2)\,a_{22}, \underline{\delta_2(3)\,a_{32}}\right] b_2(v_1) = (0,25)^2\,(0,50)^2\,(0,75)^2 \qquad \psi_3(2) = 3 \\
&\delta_3(3) = \max\left[\underline{\delta_2(1)\,a_{13}}, \delta_2(2)\,a_{23}, \delta_2(3)\,a_{33}\right] b_3(v_1) = (0,25)\,(0,50)^3\,(0,75)^2 \qquad \psi_3(3) = 1
\end{aligned}$$

$$\begin{aligned}
&\delta_4(1) = \max\left[\delta_3(1)\,a_{11}, \delta_3(2)\,a_{21}, \underline{\delta_3(3)\,a_{31}}\right] b_1(v_1) = (0,25)\,(0,50)^5\,(0,75)^2 \qquad \psi_4(1) = 3 \\
&\delta_4(2) = \max\left[\delta_3(1)\,a_{12}, \delta_3(2)\,a_{22}, \underline{\delta_3(3)\,a_{32}}\right] b_2(v_1) = (0,25)^2\,(0,50)^4\,(0,75)^2 \qquad \psi_4(2) = 3 \\
&\delta_4(3) = \max\left[\underline{\delta_3(1)\,a_{13}}, \delta_3(2)\,a_{23}, \delta_3(3)\,a_{33}\right] b_3(v_1) = (0,25)\,(0,50)^4\,(0,75)^3 \qquad \psi_4(3) = 1
\end{aligned}$$

$$\begin{aligned}
&\delta_5(1) = \max\left[\delta_4(1)\,a_{11}, \delta_4(2)\,a_{21}, \underline{\delta_4(3)\,a_{31}}\right] b_1(v_2) = (0,25)\,(0,50)^6\,(0,75)^3 \qquad \psi_5(1) = 3 \\
&\delta_5(2) = \max\left[\delta_4(1)\,a_{12}, \delta_4(2)\,a_{22}, \underline{\delta_4(3)\,a_{32}}\right] b_2(v_2) = (0,25)\,(0,50)^5\,(0,75)^4 \qquad \psi_5(2) = 3 \\
&\delta_5(3) = \max\left[\underline{\delta_4(1)\,a_{13}}, \delta_4(2)\,a_{23}, \delta_4(3)\,a_{33}\right] b_3(v_2) = (0,25)^2\,(0,50)^6\,(0,75)^2 \qquad \psi_5(3) = 1
\end{aligned}$$

$$\begin{aligned}
&\delta_6(1) = \max\left[\underline{\delta_5(1)\,a_{11}}, \delta_5(2)\,a_{21}, \delta_5(3)\,a_{31}\right] b_1(v_2) = (0,25)^2\,(0,50)^7\,(0,75)^3 \qquad \psi_6(1) = 1 \\
&\delta_6(2) = \max\left[\delta_5(1)\,a_{12}, \underline{\delta_5(2)\,a_{22}}, \delta_5(3)\,a_{32}\right] b_2(v_2) = (0,25)^2\,(0,50)^5\,(0,75)^5 \qquad \psi_6(2) = 2 \\
&\delta_6(3) = \max\left[\delta_5(1)\,a_{13}, \underline{\delta_5(2)\,a_{23}}, \delta_5(3)\,a_{33}\right] b_3(v_2) = (0,25)^2\,(0,50)^5\,(0,75)^5 \qquad \psi_6(3) = 2
\end{aligned}$$

$$\begin{aligned}
&\delta_7(1) = \max\left[\delta_6(1)\,a_{11}, \delta_6(2)\,a_{21}, \underline{\delta_6(3)\,a_{31}}\right] b_1(v_1) = (0,25)^2\,(0,50)^7\,(0,75)^5 \qquad \psi_7(1) = 3 \\
&\delta_7(2) = \max\left[\delta_6(1)\,a_{12}, \delta_6(2)\,a_{22}, \underline{\delta_6(3)\,a_{32}}\right] b_2(v_1) = (0,25)^3\,(0,50)^6\,(0,75)^5 \qquad \psi_7(2) = 3 \\
&\delta_7(3) = \max\left[\delta_6(1)\,a_{13}, \underline{\delta_6(2)\,a_{23}}, \delta_6(3)\,a_{33}\right] b_3(v_1) = (0,25)^2\,(0,50)^5\,(0,75)^7 \qquad \psi_7(3) = 2
\end{aligned}$$

$$\begin{aligned}
&\delta_8(1) = \max\left[\delta_7(1)\,a_{11}, \delta_7(2)\,a_{21}, \underline{\delta_7(3)\,a_{31}}\right] b_1(v_2) = (0,25)^2\,(0,50)^7\,(0,75)^7 \qquad \psi_8(1) = 3 \\
&\delta_8(2) = \max\left[\delta_7(1)\,a_{12}, \delta_7(2)\,a_{22}, \underline{\delta_7(3)\,a_{32}}\right] b_2(v_2) = (0,25)^2\,(0,50)^6\,(0,75)^8 \qquad \psi_8(2) = 3 \\
&\delta_8(3) = \max\left[\underline{\delta_7(1)\,a_{13}}, \delta_7(2)\,a_{23}, \delta_7(3)\,a_{33}\right] b_3(v_2) = (0,25)^3\,(0,50)^8\,(0,75)^5 \qquad \psi_8(3) = 1
\end{aligned}$$

En cada paso aparecen subrayados los términos máximos. El valor de i en cada uno de esos términos es el valor que se asigna a cada $\psi_t(j)$. La probabilidad máxima para la secuencia de observaciones completa se alcanza en $\delta_8(2)$, lo cual implica que $q_8^* = 2$, y al reconstruir hacia atrás la secuencia de estados obtenemos

$$S = (2, 3, 1, 3, 2, 2, 3, 2)$$

tal y como se puede observar también en el enrejado de la figura 3.6. En dicha figura, se han representado todos los caminos posibles mediante líneas de puntos. Posteriormente, para todos los instantes de tiempo t, excepto el primero, cada estado j se une con una línea continua al estado del instante anterior que indique $\psi_t(j)$. Por ejemplo, el estado 1 del instante de tiempo 4 aparece unido con una línea continua con el estado 3 del instante 3, ya que $\psi_4(1) = 3$. La explicación intuitiva de esta línea es la siguiente: aún no sabemos si el camino más probable pasará por el estado 1 del instante 4, pero si lo hace, entonces sabemos que pasará también por el estado 3 del instante 3. Esta *traza* se mantiene hasta el final para todos los estados. Y por último, cuando vemos que la probabilidad máxima en el instante 8 correponde al estado 2, reconstruimos el camino hacia atrás desde ese punto para obtener la secuencia de estados más probable, que es la que aparece marcada con una línea continua más gruesa. □

Para el caso que nos ocupa, que es el de la etiquetación de palabras, los cálculos involucrados en el algoritmo de Viterbi se realizan frase por frase sobre enrejados simplificados como el de la figura 3.7, donde en cada posición no se consideran todos los estados posibles, es decir, todas la etiquetas del juego de etiquetas utilizado, sino sólo las etiquetas candidatas que proponga el diccionario para cada palabra.

No obstante, como se puede observar, hemos añadido un estado especial, que denominaremos estado 0 ó `etiqueta 0`, para marcar el comienzo y el fin de frase. Conceptualmente, el propósito real de este nuevo estado es garantizar que el etiquetador simula un sistema que funciona indefinidamente en el tiempo, sin detenerse, tal y como exige el paradigma de los modelos de Markov. En la práctica, una vez que nuestro etiquetador está funcionando, la justificación coloquial es que si tenemos que etiquetar un conjunto de frases, podemos procesar unas cuantas, detener el proceso, apagar el ordenador, encenderlo al día siguiente, arrancar de nuevo el proceso, etiquetar el resto de frases, y el resultado obtenido será el mismo que si las frases hubieran sido etiquetadas todas juntas en bloque.

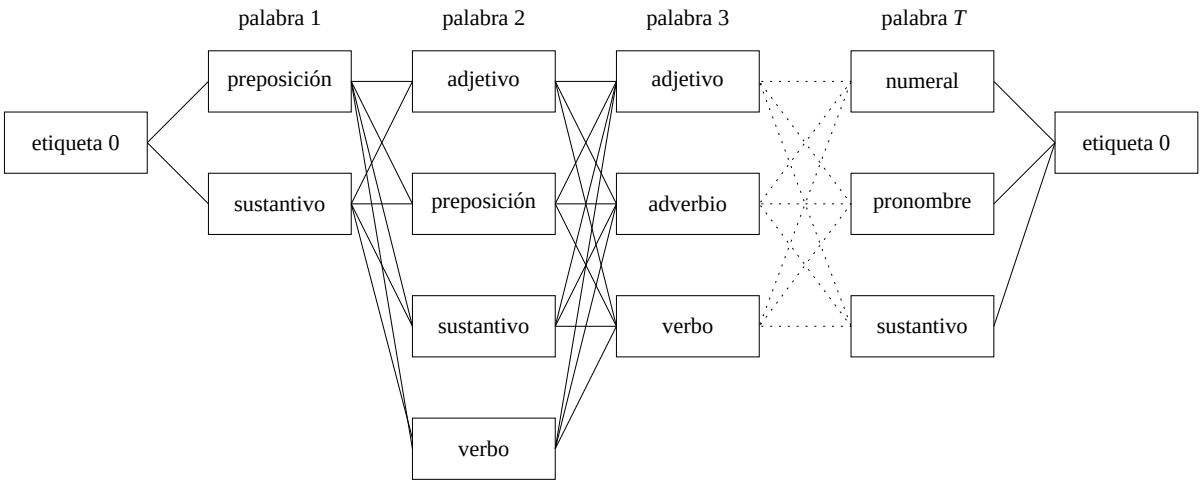

Figura 3.7: Enrejado simplificado para la etiquetación de una frase de T palabras

Los experimentos realizados por Merialdo sugieren que no existe una gran diferencia de éxito entre maximizar la probabilidad de cada etiqueta individualmente y maximizar la probabilidad de la secuencia completa, tal y como hace el algoritmo de Viterbi [Merialdo 1994]. Intuitivamente, esto es sencillo de comprender. Con el algoritmo de Viterbi, las transiciones entre estados o etiquetas son más sensibles, pero si algo va mal, se pueden obtener secuencias con varias etiquetas incorrectas. Maximizando etiqueta por etiqueta, esto no ocurre. Un fallo no desencadena otros fallos, de manera que lo que se obtiene son secuencias con errores ocasionales

dispersos. No obstante, en la práctica, el método preferido para los etiquetadores basados en HMM,s sigue siendo el algoritmo de Viterbi.

Otra cuestión que podemos considerar es si el proceso de etiquetación resulta ser reversible o no, es decir, si etiquetando las frases de izquierda a derecha se obtienen los mismos resultados que etiquetando de derecha a izquierda. Si revisamos la implementación de los algoritmos de cálculo hacia adelante y hacia atrás de la probabilidad de una secuencia de observaciones dada (algoritmos 3.1 y 3.2), veremos que ambos obtienen la misma probabilidad. Así que, en definitiva, el proceso de etiquetación no es dependiente del sentido elegido. El algoritmo de Viterbi que hemos descrito aquí se basa en el algoritmo hacia adelante y por tanto etiqueta de izquierda a derecha, mientras que el etiquetador de Church, por ejemplo, lo hace en sentido contrario [Church 1988].

Sin embargo, lo que sí es importante es que hasta ahora hemos modelizado el proceso de la etiquetación del lenguaje natural utilizando siempre HMM,s de orden 1, es decir, modelos en los que la dependencia contextual de una etiqueta se establece solamente en relación a la etiqueta anterior. A este tipo de modelos se les denomina también modelos de *bigramas* de etiquetas. Si se quiere trabajar con un HMM de orden superior, por ejemplo de orden 2, sería necesario extender los cálculos del algoritmo de Viterbi para considerar las transiciones de estados desde dos posiciones antes de la etiqueta actual, tal y como podemos ver a continuación.

Algoritmo 3.4 Cálculo de la secuencia de estados más probable para una secuencia de observaciones dada (algoritmo de Viterbi para HMM,s de orden 2):

1. Inicialización:

$$\delta_1(i) = \pi_i \, b_i(o_1), \qquad 1 \leq i \leq N.$$

$$\delta_2(i,j) = \delta_1(i) \, a_{ij} \, b_j(o_2), \qquad 1 \leq i,j \leq N. \tag{3.10}$$

2. Recurrencia:

$$\delta_{t+1}(j,k) = \left[\max_{1 \leq i \leq N} \delta_t(i,j) \, a_{ijk} \right] b_k(o_{t+1}), \qquad t = 2,3,\ldots,T-1, \qquad 1 \leq j,k \leq N.$$

$$\psi_{t+1}(j,k) = \arg \max_{1 \leq i \leq N} \delta_t(i,j) \, a_{ijk}, \qquad t = 2,3,\ldots,T-1, \qquad 1 \leq j,k \leq N.$$

3. Terminación:

$$(q^*_{T-1}, q^*_T) = \arg \max_{1 \leq j,k \leq N} \delta_T(j,k).$$

4. Construcción hacia atrás de la secuencia de estados:

$$q^*_t = \psi_{t+2}(q^*_{t+1}, q^*_{t+2}), \qquad t = T-2, T-3, \ldots, 1.$$

Obsérvese que resulta necesario almacenar tanto $a_{ij} = P(j|i)$, la distribución de probabilidad de las transiciones entre cada posible par de estados, utilizada en la ecuación (3.10), segundo paso de inicialización, como $a_{ijk} = P(k|i,j)$, la distribución de probabilidad de las transiciones entre cada posible trío de estados, utilizada en el resto de pasos del algoritmo. □

Sin embargo, en lugar de realizar esta extensión, resulta mucho más sencillo cambiar el espacio de estados del modelo por la n-ésima potencia del conjunto de etiquetas, donde n es el orden del HMM. De esta manera, es posible realizar una única implementación del algoritmo de Viterbi que sirva para cualquier orden n, con sólo introducir dicho orden como un parámetro del algoritmo. Por ejemplo, en el caso de los HMM,s de orden 2, el conjunto de estados del modelo se define como el producto cartesiano del conjunto de etiquetas, siendo válidas las transiciones entre un estado (t^i, t^l) y otro (t^m, t^k), donde todas las t^j son etiquetas, sólo cuando $l = m$. En cualquier caso, esto es lo que se conoce como modelo de *trigramas* de etiquetas, ampliamente referenciado y utilizado por la mayoría de los etiquetadores estocásticos.

Por supuesto, cabría pensar que el hecho de aumentar el orden de un HMM podría desembocar en una mejora de la representación del contexto necesario para la correcta etiquetación de las palabras. Es decir, ¿por qué considerar sólo 2 etiquetas hacia atrás, en lugar de 3, ó 4, ó incluso más? Esto no se lleva a cabo en la práctica porque las unidades de información mayores que el trigrama generalmente modelizan fenómenos lingüísticos muy complejos y que afectan a muy pocos idiomas, resultando por ello suficientemente adecuado el uso de los trigramas. Por otra parte, el gran problema de aumentar el orden de un HMM es que crece desorbitadamente el número de parámetros que es necesario estimar para hacer operativo el modelo, tal y como veremos más adelante.

3.4.2.2 Implementaciones alternativas del algoritmo de Viterbi

Dado que el algoritmo de Viterbi no calcula una probabilidad exacta, sino que construye una secuencia de estados, podemos tomar logaritmos sobre los parámetros del modelo e implementarlo sólo con sumas, sin necesidad de ninguna multiplicación. De esta manera, no sólo se evita el problema de la rápida pérdida de precisión debida a las multiplicaciones de números muy pequeños, sino que además la velocidad de ejecución aumenta ya que las sumas se realizan más rápido que las multiplicaciones. En la práctica, es particularmente importante disponer de una implementación muy eficiente de este algoritmo, porque es el que realmente etiqueta las palabras que aparecen en los textos, mientras que el proceso de estimación de los parámetros del modelo, que veremos en la siguiente sección, puede realizarse de manera previa y separada, y por tanto su velocidad no es tan crítica. Los pasos del nuevo algoritmo son los siguientes.

Algoritmo 3.5 Cálculo de la secuencia de estados más probable para una secuencia de observaciones dada (algoritmo de Viterbi con logaritmos y sumas):

0. Preproceso:
$$\begin{aligned} &\tilde{\pi}_i = \log(\pi_i), && 1 \le i \le N. \\ &\tilde{a}_{ij} = \log(a_{ij}), && 1 \le i, j \le N. \\ &\tilde{b}_i(o_t) = \log[b_i(o_t)], && 1 \le i \le N,\ 1 \le t \le T. \end{aligned}$$

1. Inicialización:
$$\tilde{\delta}_1(i) = \log[\delta_1(i)] = \tilde{\pi}_i + \tilde{b}_i(o_1), \qquad 1 \le i \le N.$$

2. Recurrencia:
$$\tilde{\delta}_{t+1}(j) = \log[\delta_{t+1}(j)] = \left[\max_{1 \le i \le N}[\tilde{\delta}_t(i) + \tilde{a}_{ij}]\right] + \tilde{b}_j(o_{t+1}), \quad t = 1, 2, \ldots, T-1, \quad 1 \le j \le N.$$

$$\psi_{t+1}(j) = \arg\max_{1 \le i \le N}[\tilde{\delta}_t(i) + \tilde{a}_{ij}], \qquad t = 1, 2, \ldots, T-1, \qquad 1 \le j \le N.$$

3. Terminación:

$$q_T^* = \arg \max_{1 \leq i \leq N} \tilde{\delta}_T(i).$$

4. Construcción hacia atrás de la secuencia de estados:

$$q_t^* = \psi_{t+1}(q_{t+1}^*), \qquad t = T-1, T-2, \ldots, 1.$$

Esta implementación alternativa requiere del orden de N^2T sumas, más los cálculos necesarios para el paso de preproceso. No obstante, dado que el paso de preproceso normalmente se realiza una sola vez y se almacenan los resultados, su coste es despreciable en la mayoría de las aplicaciones. □

Por otra parte, el tiempo de procesamiento del algoritmo de Viterbi también se puede reducir introduciendo una búsqueda con corte[3]: cada estado que recibe un valor δ menor que el δ máximo hasta ese instante dividido por un cierto umbral θ queda excluido de los cálculos. Por supuesto, la incorporación de esta búsqueda con corte ya no garantiza que el algoritmo de Viterbi encuentre la secuencia de estados de máxima probabilidad. Sin embargo, para propósitos prácticos y con una buena elección del umbral θ, no existe virtualmente ninguna diferencia de precisión entre los algoritmos con y sin corte. Empíricamente, un valor de $\theta = 1.000$ puede aproximadamente doblar la velocidad de un etiquetador sin afectar a la precisión [Brants 2000].

3.4.3 Estimación de los parámetros del modelo

Dada una secuencia de observaciones O, el tercer problema fundamental relativo a los HMM,s consiste en determinar los parámetros del modelo que mejor *explican* los datos observados. Para el caso que nos ocupa, que es el de la etiquetación, dichas observaciones se corresponden con las palabras de un texto en lenguaje natural. En general, existen dos posibles métodos de estimación claramente diferenciados, en función de si el texto que observamos ha sido ya previamente etiquetado o no.

Con el fin de seguir el orden cronológico en el que han ido apareciendo las distintas técnicas, consideraremos primero el caso en el que el texto que observamos no está etiquetado. En este caso, es posible realizar un proceso de estimación, que denominaremos *no visible* o no supervisado, mediante el algoritmo de Baum-Welch. Sin embargo, veremos que un texto no etiquetado por sí solo no es suficiente para entrenar el modelo. Es necesario contar también con la ayuda de otro recurso lingüístico en forma de diccionario, que permita obtener un buen punto de inicialización para dicho algoritmo. Posteriormente, a medida que aparecieron disponibles los textos etiquetados, fue surgiendo también otro tipo de proceso de estimación que denominaremos *visible* o supervisado.

3.4.3.1 Estimación no supervisada: algoritmo de Baum-Welch

Cuando se dispone de una observación O, formada por un texto que no ha sido previamente etiquetado, este tercer problema de la estimación de los parámetros es el más complejo, ya que no se conoce ningún método analítico definitivo para encontrar un modelo $\mu = (\pi, A, B)$ que maximice $P(O|\mu)$. Sin embargo, podemos elegir un modelo que maximice localmente dicha probabilidad mediante un procedimiento iterativo tal como el algoritmo de Baum-Welch, que es un caso especial del algoritmo EM[4] [Dempster *et al.* 1977].

[3] *Beam search* o *purging*.

[4] *Expectation-Maximization* (maximización de la esperanza); la parte E del algoritmo de Baum-Welch se conoce también como algoritmo *forward-backward* (hacia adelante y hacia atrás) [Baum 1972].

La idea intuitiva del algoritmo de Baum-Welch es la siguiente. En un primer momento, no sabemos cómo es el modelo, pero podemos trabajar sobre la probabilidad de la secuencia de observaciones utilizando algún modelo inicial, quizás preseleccionado o simplemente elegido de forma aleatoria. A partir de ese cálculo, identificamos qué transiciones y qué símbolos de emisión son los más probables. Incrementando la probabilidad de esas transiciones y de esos símbolos, construimos un modelo revisado, el cual obtendrá una probabilidad mayor que el modelo anterior para la secuencia de observaciones dada. Este proceso de maximización, denominado normalmente *proceso de entrenamiento*, se repite un cierto número de veces. Finalmente, el algoritmo se detiene cuando no consigue construir un modelo que mejore la probabilidad de la secuencia de observaciones dada.

Para describir formalmente este procedimiento, definimos primero $\xi_t(i,j)$, la probabilidad de estar en el estado i en el instante t y en el estado j en el instante $t+1$, dada la observación y dado el modelo, es decir,

$$\xi_t(i,j) = P(q_t = i, q_{t+1} = j | O, \mu). \tag{3.11}$$

Los caminos que satisfacen las condiciones requeridas por la ecuación (3.11) son los que se muestran en la figura 3.8. Por tanto, a partir de las definiciones de las variables hacia adelante y hacia atrás, podemos escribir $\xi_t(i,j)$ de la forma

$$\xi_t(i,j) = \frac{P(q_t = i, q_{t+1} = j, O|\mu)}{P(O|\mu)} = \frac{\alpha_t(i)\, a_{ij}\, b_j(o_{t+1})\, \beta_{t+1}(j)}{P(O|\mu)} = \frac{\alpha_t(i)\, a_{ij}\, b_j(o_{t+1})\, \beta_{t+1}(j)}{\sum_{k=1}^{N}\sum_{l=1}^{N} \alpha_t(k)\, a_{kl}\, b_l(o_{t+1})\, \beta_{t+1}(l)}.$$

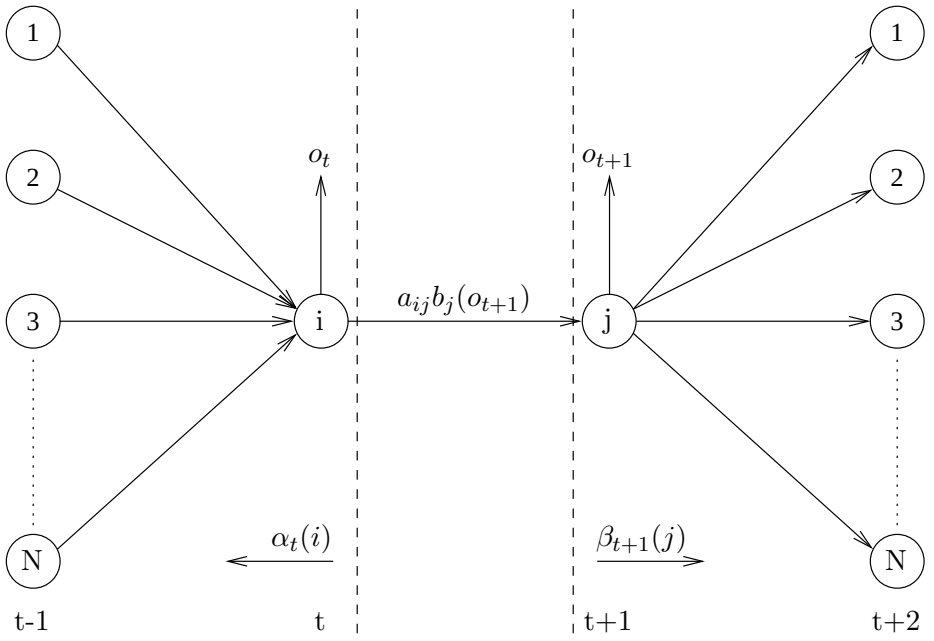

Figura 3.8: Detalle de la secuencia de operaciones necesarias para el cálculo de la probabilidad conjunta de que el sistema esté en el estado i en el instante t y en el estado j en el instante $t+1$

Previamente, en las ecuaciones (3.5) y (3.6), habíamos definido también $\gamma_t(i)$ como la probabilidad de estar en el estado i en el instante t, dada la secuencia de obsevaciones y dado el modelo. Por tanto, podemos relacionar $\gamma_t(i)$ con $\xi_t(i,j)$ mediante un sumatorio que recorre

todo el espacio de estados sobre el índice j, dejando fijo el estado i, es decir,

$$\gamma_t(i) = \sum_{j=1}^{N} \xi_t(i,j).$$

Si sumamos $\gamma_t(i)$ a lo largo del tiempo, obtenemos un valor que se puede interpretar como el número esperado de veces que se visita el estado i, o lo que es lo mismo, el número esperado de transiciones hechas desde el estado i, si eliminamos del sumatorio el instante de tiempo $t = T$. De manera similar, el sumatorio de $\xi_t(i,j)$ sobre t, también desde $t = 1$ hasta $t = T-1$, se puede interpretar como el número esperado de transiciones desde el estado i al estado j. Es decir,

$$\sum_{t=1}^{T-1} \gamma_t(i) = \text{número esperado de transiciones desde el estado } i \text{ en } O,$$

$$\sum_{t=1}^{T-1} \xi_t(i,j) = \text{número esperado de transiciones desde el estado } i \text{ al estado } j \text{ en } O.$$

Utilizando estas fórmulas, se puede dar un método general para reestimar los parámetros de un HMM.

Algoritmo 3.6 Reestimación de los parámetros de un HMM (algoritmo de Baum-Welch). El conjunto de ecuaciones para la reestimación de π, A y B es el siguiente:

$$\bar{\pi}_i = \text{frecuencia esperada de estar en el estado } i \text{ en el primer instante } = \gamma_1(i),$$

$$\bar{a}_{ij} = \frac{\text{número esperado de transiciones desde el estado } i \text{ al estado } j}{\text{número esperado de transiciones desde el estado } i} = \frac{\sum_{t=1}^{T-1} \xi_t(i,j)}{\sum_{t=1}^{T-1} \gamma_t(i)},$$

$$\bar{b}_j(v_k) = \frac{\text{número esperado de veces en el estado } j \text{ observando el símbolo } v_k}{\text{número esperado de veces en el estado } j} = \frac{\sum_{t=1}^{T} \gamma_t(j) \text{ tal que } o_t = v_k}{\sum_{t=1}^{T} \gamma_t(j)}.$$

Si definimos el modelo actual como $\mu = (\pi, A, B)$ y lo utilizamos para calcular los términos que aparecen en las partes derechas de las tres ecuaciones anteriores, y definimos el modelo reestimado como $\bar{\mu} = (\bar{\pi}, \bar{A}, \bar{B})$ a partir de los valores obtenidos para las partes izquierdas de dichas ecuaciones, está demostrado por Baum que: o bien (1) el modelo inicial μ define un punto crítico para la función de probabilidad, en cuyo caso $\bar{\mu} = \mu$; o bien (2) el modelo $\bar{\mu}$ es más probable que el modelo μ en el sentido de que $P(O|\bar{\mu}) > P(O|\mu)$, esto es, hemos encontrado un nuevo modelo $\bar{\mu}$ para el cual la probabilidad de generar la secuencia de observaciones es mayor. Así pues, reemplazando μ por $\bar{\mu}$ y repitiendo la reestimación de los parámetros un cierto número de veces, podemos mejorar la probabilidad de O en cada iteración, hasta que no se aprecie ninguna ganancia significativa. □

Sin embargo, este método para la reestimación de los parámetros es muy sensible a las condiciones de inicialización del modelo. Es decir, el método no garantiza que encontremos el mejor modelo, ya que, debido a una inicialización incorrecta, el proceso podría detenerse en un máximo local, y en la mayoría de los problemas reales la función de probabilidad suele ser muy compleja, no lineal y con numerosos máximos locales. Por tanto, para encontrar el máximo global, una posible aproximación es intentar inicializar el modelo en una región del espacio de parámetros cercana a ese máximo global. En definitiva, una inicialización aleatoria podría dejar el problema de la reestimación de parámetros demasiado abierto y la manera de restringir el problema es elegir unos parámetros adecuados, en lugar de fijarlos aleatoriamente.

Algunos autores consideran que en la práctica, una estimación inicial de los parámetros π y A con números aproximadamente iguales, ligeramente perturbados para evitar los máximos locales, pero que respeten las restricciones estocásticas estándar y que sean siempre distintos de cero, suele ser normalmente satisfactoria para que posteriormente el algoritmo de Baum-Welch aprenda por sí solo la regularidad de las etiquetas, es decir, todo lo relativo a los transiciones entre los estados del modelo. Sin embargo esto no es más que una confusión que parte de la creencia general de que cuando un sistema tiene la capacidad de aprender, debe aprenderlo todo por sí mismo. Esto es efectivamente falso. Cuanta más información se le proporcione inicialmente al sistema, mejor[5]. Es decir, en nuestro caso, se ha demostrado que siempre se van a obtener mejores resultados cuando se inicializan los parámetros π y A a partir de un texto etiquetado, por pequeño que sea. Dicho texto podría ser construido manualmente si no se dispone de ninguno. Incluso repetir unas cuantas veces la estrategia de construir un modelo inicial, etiquetar otra pequeña porción de texto, corregirla manualmente, y utilizarla para estimar de nuevo los parámetros del modelo, ofrecería mejores resultados que la aplicación a ciegas del método de Baum-Welch. En definitiva, lo que queremos señalar es que la división entre métodos de estimación visible y no visible no es en nuestro caso tan estricta como la estamos presentando aquí. O si se prefiere, podríamos decir que, en sentido estricto, la estimación totalmente no visible no existe.

En cualquier caso, cuando no se dispone de textos etiquetados, o cuando estos son muy pequeños, resulta importante obtener un buen valor inicial para el parámetro B, es decir, para las probabilidades de emisión de las palabras, lo cual puede hacerse mediante el uso de un diccionario. Existen dos métodos generales para realizar esta inicialización: el método de Jelinek y el método de Kupiec. A continuación esbozamos cada uno de ellos:

- **Método de Jelinek**. Si definimos $Q(v_k)$ como el número de etiquetas permitidas para la palabra v_k en el diccionario, $C(v_k)$ como el número de apariciones de la palabra v_k en el corpus de entrenamiento, y $b_j^*(v_k)$ como

$$b_j^*(v_k) = \begin{cases} 0 & \text{si } j \text{ no es una etiqueta permitida para la palabra } v_k \\ \frac{1}{Q(v_k)} & \text{en caso contrario,} \end{cases}$$

[5]Por supuesto, esta idea de considerar como modelo más preciso el que más se acerca a los datos disponibles, llevada al extremo, degenera en un tratamiento manual específico para cualquier nuevo corpus, lo cual no es en absoluto realista. Ésta es la razón por la cual se desarrollan modelos abstractos y técnicas de aprendizaje: para que los sistemas se adapten rápidamente a los nuevos datos y sean capaces de manejarlos adecuadamente. Por tanto, se debe encontrar un equilibrio entre: por un lado, la descripción del modelo (y la dificultad de parametrizarlo), y por otro, su posibilidad de adaptación (es decir, su aprendizaje) con respecto al volumen de datos. Desde el punto de vista de la estadística y del aprendizaje, esto se conoce como el *Bias-Variance balance* (balance del sesgo y la varianza).

entonces se inicializa $b_j(v_k)$ con el valor

$$b_j(v_k) = \frac{b_j^*(v_k)\, C(v_k)}{\sum_m b_j^*(v_m)\, C(v_m)}.$$

Es decir, el método de Jelinek inicializa las probabilidades de emisión del modelo mediante el uso de la regla de Bayes, estimando mediante la frecuencia observada la probabilidad de aparición de una palabra y suponiendo que todas las etiquetas que aparecen en el diccionario para una palabra dada son igualmente probables [Jelinek 1985].

- **Método de Kupiec**. La otra alternativa es agrupar las palabras en clases de ambigüedad, de tal manera que todas aquellas palabras que tengan el mismo conjunto de etiquetas permitidas en el diccionario pertenezcan a la misma clase o *metapalabra* u_L, donde L es un subconjunto de Q, el conjunto de etiquetas utilizado. Es decir, si $L(v_k)$ es el conjunto de todas las etiquetas posibles para la palabra v_k, entonces

$$u_L = \{v_k \mid L = L(v_k)\}, \qquad \forall L \subseteq Q.$$

Por ejemplo, la metapalabra $u_{\{\texttt{Scms},\texttt{P}\}}$ contendrá todas las palabras para las cuales el diccionario permite las etiquetas `Scms`, es decir, sustantivo común masculino singular, y `P`, es decir, preposición, y ninguna otra etiqueta más. Entonces, a cada una de estas metapalabras se le da un tratamiento similar al del método de Jelinek:

$$b_j^*(u_L) = \begin{cases} 0 & \text{si } j \notin L \\ \frac{1}{|L|} & \text{en caso contrario,} \end{cases}$$

donde $|L|$ es el cardinal del conjunto L, y

$$b_j(u_L) = \frac{b_j^*(u_L)\, C(u_L)}{\sum_{L'} b_j^*(u_{L'})\, C(u_{L'})}$$

donde $C(u_L)$ (respectivamente $C(u_{L'})$) es el número de palabras pertenecientes a u_L (respectivamente $u_{L'}$) que aparecen en el corpus de entrenamiento. La implementación real utilizada por Kupiec es una variante de la presentada aquí, pero se ha expuesto de esta manera para hacer más transparente la similitud entre ambos métodos. Por ejemplo, Kupiec no incluye las 100 palabras más frecuentes dentro de las clases de ambigüedad, sino que las trata separadamente como clases de una sola palabra, con el fin de no introducir errores y mejorar así la estimación inicial [Kupiec 1992].

La ventaja del método de Kupiec sobre el de Jelinek es que no necesita afinar una probabilidad de emisión diferente para cada palabra. Mediante la definición de estas clases de ambigüedad, el número total de parámetros se reduce substancialmente y éstos se pueden estimar de una manera más precisa. Por supuesto, esta ventaja podría convertirse en desventaja si existe la suficiente cantidad de material de entrenamiento como para estimar los parámetros palabra por palabra tal y como hace el método de Jelinek.

En el algoritmo de Baum-Welch también es necesario hacer algo para evitar el problema de la pérdida de precisión en punto flotante. Sin embargo, la necesidad de realizar sumas dificulta el uso de logaritmos. Una solución bastante común es utilizar unos coeficientes auxiliares de escalado, cuyos valores crecen con el tiempo de manera que si se multiplican las

probabilidades por esos coeficientes, éstas siempre se mantienen dentro del rango de punto flotante del ordenador. Al final de cada iteración, cuando efectivamente se reestiman los parámetros, se cancela el uso de esos coeficientes [Rabiner y Juang 1993, pp. 365-368]. Otra alternativa es utilizar igualmente logaritmos y utilizar la función que mostramos a continuación para sumarlos.

Algoritmo 3.7 Función para la suma de logaritmos. Dados $x = \log(x')$ e $y = \log(y')$, la función calcula $\log(x' + y')$:

```
function Sumar_Logaritmos (x, y) =
  begin
    if (y − x > log C) then
      return y
    else
      if (x − y > log C) then
        return x
      else
        return min (x, y) + log (exp (x − min (x, y)) + exp (y − min (x, y)))
  end;
```

En esta porción de pseudo-código, C representa una constante grande, del orden de 10^{30}. De esta manera, lo que estamos haciendo es calcular un factor de escalado apropiado en el momento de realizar cada suma, y lo único que resta es tener cuidado con los errores de redondeo. □

3.4.3.2 Estimación supervisada: métodos de suavización

Cuando se dispone de un texto etiquetado, la primera idea que acude a nuestra mente para abordar el proceso de estimación de los parámetros del modelo es quizás la de diseñar un sencillo mecanismo basado en el uso de frecuencias relativas. Pero antes de comentar dicho mecanismo, vamos a introducir un cambio en la notación que hace referencia a la definición formal de los HMM,s.

Hasta aquí, la notación que hemos utilizado estaba inspirada en la excelente presentación que Rabiner llevó a cabo en relación con este tipo de procesos estocásticos [Rabiner 1989]. Efectivamente, se trata de una notación genérica sobre HMM,s especialmente orientada a describir con el máximo detalle la implementación de determinados algoritmos, como pueden ser el de Viterbi o el de Baum-Welch. Sin embargo, una vez que hemos centrado la discusión sobre el tema concreto de la etiquetación, algunos aspectos de esa notación no se identifican con nuestro problema todo lo bien que nos gustaría. Por poner un ejemplo, los estados de un HMM habían sido denotados simplemente con los números enteros del conjunto $\{1, 2, \ldots, N\}$. Esto facilita mucho la expresión de operaciones tales como la indexación de las celdas de la matriz A de transiciones entre estados, pero no nos permite hacer referencia a las etiquetas concretas que se están utilizando, si no es a través de la consideración de una función correspondencia entre ambos conjuntos.

La notación que proponemos ahora está más acorde con la que se adopta en la mayoría de las referencias bibliográficas dedicadas específicamente al tema de la etiquetación.

Definición 3.2 Básicamente, la nueva notación describe cada uno de los elementos de un HMM como sigue:

1. Considerando la inicial de la palabra inglesa *tag* (etiqueta), denotaremos mediante t^i la i-ésima etiqueta del conjunto de etiquetas utilizado, y mediante t_i la etiqueta de la palabra

que ocupa la posición i dentro de la frase que se está tratando. De esta manera, en el modelo de bigramas, los estados se denotan también mediante t^i, es decir, mediante el nombre de las propias etiquetas. Y si el modelo está basado en trigramas, los estados serán de la forma (t^i, t^j), donde cada uno de estos pares proviene del producto cartesiano del conjunto de etiquetas utilizado, tal y como ya habíamos esbozado.

2. Anteriormente, habíamos denotado mediante v_k cada uno de los símbolos de observación correspondientes a la parte *visible* del modelo, y habíamos visto que, en el caso de la etiquetación, dichos sucesos observables se corresponden con las palabras. Pues bien, de igual manera, considerando la inicial del vocablo inglés *word* (palabra), denotaremos ahora mediante w^i la i-ésima palabra del diccionario, y mediante w_i la palabra que ocupa la posición i dentro de la frase.

3. Habíamos indicado también que trabajaremos siempre en el nivel de frase, y que consideraremos un estado o etiqueta especial t^0 para marcar el inicio y el final de cada una de las frases. Por tanto, respecto al parámetro π, la distribución de probabilidad del estado inicial, tendremos que $\pi(t^0)$ será igual a 1, y $\pi(t^i)$ será igual a 0, para todo $i = 1, 2, \ldots, N$.

4. Por lo que respecta al parámetro A, la distribución de probabilidad de las transiciones entre estados, basta aclarar que, de acuerdo con la nueva notación, la información que realmente está almacenada en cada una de las celdas de esta matriz es $P(t^j|t^i)$ en el caso de los modelos basados en bigramas, y $P(t^k|t^i\, t^j)$ en el caso de los modelos basados en trigramas.

5. Por último, respecto a B, las probabilidades de emisión de las palabras, simplemente indicamos que la información que antes se denotaba mediante $b_j(v_k)$ se escribe ahora como $P(w^k|t^j)$.

Para terminar, completamos esta notación con algunos aspectos que nos permitirán avanzar más cómodamente con la exposición. Denotaremos mediante $C(x)$ el número de veces que el suceso x aparece en el corpus de entrenamiento. Por ejemplo, $C(t^i, t^j, t^k)$ representa el número de veces que aparece el trigrama $t^i\, t^j\, t^k$. De igual manera, $C(w^k|t^j)$ representa el número de veces que aparece la palabra w^k etiquetada como t^j. Denotaremos también mediante $f(x)$ la frecuencia del suceso x en el corpus de entrenamiento. Y finalmente denotaremos mediante $\hat{p}(x)$ nuestra estimación de la probabilidad real $P(x)$. □

Nuevo modelo probabilístico. La etiquetación se describe entonces, a través de esta nueva notación, como el proceso de encontrar la mejor secuencia de etiquetas $t_{1,n}$ para una frase dada de n palabras $w_{1,n}$. Aplicando la regla de Bayes, podemos escribir:

$$\arg\max_{t_{1,n}} P(t_{1,n}|w_{1,n}) = \arg\max_{t_{1,n}} \frac{P(w_{1,n}|t_{1,n})P(t_{1,n})}{P(w_{1,n})} = \arg\max_{t_{1,n}} P(w_{1,n}|t_{1,n})P(t_{1,n}).$$

Ahora, trabajamos sobre esta expresión para conseguir que utilice los parámetros que podemos estimar directamente desde el corpus de entrenamiento. Para ello, además de la propiedad del horizonte limitado (3.14), utilizamos dos suposiciones más acerca de las palabras:

1. Las etiquetas no son independientes unas de otras, pero las palabras sí (3.12).

2. La identidad de una palabra depende sólo de su propia etiqueta (3.13).

Así pues, tenemos que:

$$P(w_{1,n}|t_{1,n})P(t_{1,n}) =$$

$$= \left(\prod_{i=1}^{n} P(w_i|t_{1,n})\right) \times P(t_n|t_{1,n-1}) \times P(t_{n-1}|t_{1,n-2}) \times \ldots \times P(t_2|t_1) = \tag{3.12}$$

$$= \left(\prod_{i=1}^{n} P(w_i|t_i)\right) \times P(t_n|t_{1,n-1}) \times P(t_{n-1}|t_{1,n-2}) \times \ldots \times P(t_2|t_1) = \tag{3.13}$$

$$= \left(\prod_{i=1}^{n} P(w_i|t_i)\right) \times P(t_n|t_{n-1}) \times P(t_{n-1}|t_{n-2}) \times \ldots \times P(t_2|t_1) = \tag{3.14}$$

$$= \prod_{i=1}^{n} [P(w_i|t_i) \times P(t_i|t_{i-1})].$$

Por tanto, la ecuación final para determinar la secuencia de etiquetas óptima para una frase dada es

$$\hat{t}_{1,n} = \arg\max_{t_{1,n}} P(t_{1,n}|w_{1,n}) = \arg\max_{t_{1,n}} \prod_{i=1}^{n} [P(w_i|t_i) \times P(t_i|t_{i-1})]$$

para los etiquetadores basados en bigramas, y

$$\hat{t}_{1,n} = \arg\max_{t_{1,n}} P(t_{1,n}|w_{1,n}) = \arg\max_{t_{1,n}} \prod_{i=1}^{n} [P(w_i|t_i) \times P(t_i|t_{i-2}, t_{i-1})]$$

para los etiquetadores basados en trigramas. Estos cálculos son precisamente los que realiza el algoritmo de Viterbi, de tal manera que para disponer de un etiquetador totalmente operativo sólo resta especificar de qué manera se pueden obtener los parámetros de funcionamiento del HMM subyacente. La sección anterior presentaba un método para la estimación de dichos parámetros a partir de textos no etiquetados. Ahora nos ocuparemos del diseño de métodos de estimación de parámetros a partir de textos etiquetados.

Retomemos entonces la idea inicial de diseñar un mecanismo intuitivo para estimar los parámetros de nuestro modelo. Dado que en este caso partimos de un texto previamente etiquetado, podemos sugerir que el proceso de estimación de las transiciones entre estados podría realizarse en base a unos sencillos cálculos de frecuencias relativas. En el caso de un modelo basado en bigramas, tendríamos que

$$\hat{p}(t^j|t^i) = f(t^j|t^i) = \frac{C(t^i, t^j)}{C(t^i)}.$$

En el caso de un modelo basado en trigramas, tendríamos que

$$\hat{p}(t^k|t^i\, t^j) = f(t^k|t^i\, t^j) = \frac{C(t^i, t^j, t^k)}{C(t^i, t^j)}.$$

De igual manera, para la estimación de las probabilidades de emisión de las palabras, tendríamos que

$$\hat{p}(w^k|t^j) = f(w^k|t^j) = \frac{C(w^k|t^j)}{C(t^j)}.$$

Hasta aquí, lo que hacemos no es realmente estimar, sino construir un modelo de manera visible. Una vez que este modelo está preparado, podemos utilizarlo para etiquetar nuevos textos mediante la aplicación del algoritmo de Viterbi a cada una de sus frases, y la idea original de modelo oculto vuelve a tener sentido.

Sin embargo, antes de utilizar directamente un modelo construido a partir de frecuencias relativas, es necesario hacer la siguiente reflexión. Pensemos en un caso práctico real, como por ejemplo el experimento realizado con un corpus en español[6]. El cardinal del juego de etiquetas utilizado en dicho experimento es de 373 etiquetas. Esto no quiere decir que una frase de longitud n palabras deba ser etiquetada aplicando el algoritmo de Viterbi sobre un enrejado de $373 \times n$ estados, sino más bien sobre un enrejado simplificado como el que veíamos en la figura 3.7, donde se consideran sólo las posibles etiquetas de cada palabra. Lo que sí quiere decir es que, en el caso de un modelo basado en bigramas, la matriz A contendría $373 \times 373 = 139.129$ celdas, y sin embargo, en el mayor de los corpus de entrenamiento utilizados en dicho experimento, tan solo se pueden ver 4.037 de esas transiciones (es decir, el $2,90\%$), y las restantes celdas quedarían a cero. En el caso de un modelo basado en trigramas, la matriz A contendría $373 \times 373 \times 373 = 51.895.117$ celdas, sólo se pueden llegar a ver 23.119 (el $0,04\%$), y las restantes quedarían también a cero. Esto es debido al fenómeno de *dispersión de los datos*[7], el cual puede provocar también que algunas de esas transiciones aparezcan como candidatas a la hora de etiquetar nuevas frases.

Así pues, teniendo en cuenta que los enrejados simplificados ya contemplan sólo un subconjunto reducido de todos los caminos posibles, parece muy arriesgado trabajar con transiciones nulas, cuyo uso implica multiplicaciones por cero que anularían completamente todos los caminos que pasen por ellas. Para evitar el problema de las transiciones nulas, se suelen utilizar *métodos de suavización*[8]. Estos métodos permiten que a partir de muestras pequeñas se puedan estimar unas probabilidades más representativas del comportamiento real de la población que estamos estudiando.

Una forma de implementar la suavización es mediante técnicas de *interpolación lineal*. En general, el esquema de suavizado mediante interpolación lineal funciona como sigue. La distribución $f(x)$ observada en un conjunto de E posibles sucesos se modifica añadiendo un valor muy pequeño procedente de una distribución menos específica $q(x)$ a la cual damos un peso o confianza α. Entonces, la distribución de probabilidad que nos interesa se aproxima de la siguiente forma:

$$\hat{p}(x) \approx \frac{f(x) + \alpha\, q(x)}{E + \alpha}.$$

Y si utilizamos el parámetro tradicional de interpolación $\lambda = \frac{\alpha}{E+\alpha}$, entonces también se verifica la siguiente aproximación:

$$\hat{p}(x) \approx (1 - \lambda)\, \frac{f(x)}{E} + \lambda\, q(x).$$

Es decir, si lo que queremos estimar son las probabilidades de transición entre estados de un modelo basado en bigramas, esa distribución menos específica ponderada con α al interpolar puede ser la distribución de probabilidad de los *unigramas*, esto es, la distribución de probabilidad de cada etiqueta individualmente[9]. Por tanto, las probabilidades de los bigramas se pueden aproximar mediante

$$\hat{p}(t_i|t_{i-1}) = (1 - \lambda)\, f(t_i|t_{i-1}) + \lambda\, f(t_i)$$

[6]Se trata de un experimento realizado con la versión en español del corpus ITU (*International Telecommunications Union CCITT Handbook*). Los datos relativos a este experimento se encuentran en [Graña 2000].

[7]También denominado fenómeno de *sparse data*.

[8]También denominados métodos de *smoothing*.

[9]Esta fórmula viene del hecho de que $P(X|Y) = P(X)$, si X e Y son independientes. Por eso decimos que $P(X|Y)$ se estima mediante $f(X|Y)$, o en todo caso mediante una combinación lineal de $f(X|Y)$ y $f(X)$, si el bigrama $Y\,X$ aparece en el corpus de entrenamiento, y mediante $f(X)$ si no aparece, asumiendo la hipótesis de independencia para esos sucesos perdidos. Rigurosamente hablando esto no es correcto, pero constituye una buena aproximación de primer orden (considerando la hipótesis de Markov como una hipótesis de segundo orden).

y las de los trigramas mediante

$$\hat{p}(t_i|t_{i-2}\,t_{i-1}) = \lambda_3\, f(t_i|t_{i-2}\,t_{i-1}) + \lambda_2\, f(t_i|t_{i-1}) + \lambda_1\, f(t_i) \tag{3.15}$$

donde todos los *pesos* λ_i deben ser no negativos y deben satisfacer la restricción $\lambda_1+\lambda_2+\lambda_3 = 1$. A continuación, y centrando ya toda nuestra atención en el modelo de trigramas, discutiremos cómo elegir los pesos λ_i de manera óptima.

Suavizado lineal óptimo. Un modelo de lenguaje que opere de acuerdo con la ecuación (3.15) se puede ver realmente como un HMM. La figura 3.9 muestra un fragmento de este modelo. En este punto es importante aclarar la siguiente cuestión. Existe una variante de representación de los HMM,s que lleva asociadas las probabilidades de emisión no a un único estado, sino tanto al estado origen como al estado destino de las transiciones. Es decir, dichas probabilidades de emisión están asociadas realmente a los arcos o transiciones, no a los estados individuales. Algunos autores prefieren enfocar la introducción a los HMM,s comenzando con este tipo de representación, ya que el paso de generalización desde los HMM,s con probabilidades de emisión en los arcos a los HMM,s con probabilidades de emisión en los estados resulta más natural que el paso inverso. A pesar de esto, nosotros hemos preferido manejar desde el principio HMM,s con probabilidades de emisión en los estados, porque este es el tipo de HMM,s que efectivamente se utiliza en la práctica para la etiquetación de textos, y por tanto es posible establecer analogías entre ambos conceptos desde el primer momento.

No obstante, el HMM de la figura 3.9 es un HMM con probabilidades de emisión en los arcos. Ocurre además que en este tipo de HMM,s está permitido el uso de transiciones que no emiten ningún símbolo, sino que simplemente se utilizan para cambiar de estado. Este tipo de transiciones se denominan *transiciones épsilon* o *transiciones vacías*. En la figura, no aparecen representados los símbolos de salida, sino simplemente las probabilidades de cada arco. Por tanto, para distinguir las transiciones normales de las transiciones épsilon, hemos representado estas últimas mediante líneas discontinuas. Así pues, saliendo del estado más a la izquierda (t^i, t^j) tenemos tres transiciones vacías que van a los pseudo-estados $s_1(t^i, t^j)$, $s_2(t^i, t^j)$ y $s_3(t^i, t^j)$. Las probabilidades de estas transiciones son λ_1, λ_2 y λ_3, respectivamente. A continuación, saliendo de cada uno de los tres pseudo-estados aparecen N transiciones. Cada una de ellas conduce a un estado (t^j, t^k), $k = 1, 2, \ldots, N$, para generar la tercera etiqueta del trigrama. Las probabilidades de estas transiciones son $f(t^k)$, $f(t^k|t^j)$ y $f(t^k|t^i\,t^j)$, $k = 1, 2, \ldots, N$, respectivamente. En la figura, hemos etiquetado sólo las transiciones que entran en los estados (t^j, t^1) y (t^j, t^N). Nótese que desde el estado más a la izquierda (t^i, t^j) se puede alcanzar cada uno de estos estados a través de tres caminos posibles, y que por tanto la probabilidad total de llegar a cada estado coincide con el cálculo de la ecuación (3.15).

Por supuesto, otra forma de ver el problema podría ser considerando el HMM de la figura 3.9 todavía como un HMM con probabilidades de emisión en los estados, salvo que ahora es a los pseudo-estados $s_1(t^i, t^j)$, $s_2(t^i, t^j)$ y $s_3(t^i, t^j)$ a los que no se les permite generar ninguna palabra. En cualquier caso, tenemos que las probabilidades de las transiciones normales son conocidas, mientras que las de las transiciones épsilon, λ_1, λ_2 y λ_3, deben ser determinadas mediante algún procedimiento. El HMM completo es desde luego enorme: consta de $4 \times N^2$ estados, donde N es el tamaño del conjunto de etiquetas utilizado. Pero de acuerdo con la ecuación (3.15), para un i dado, $i \in \{1, 2, 3\}$, todas las probabilidades λ_i de las transiciones que van desde el estado más a la izquierda (t^i, t^j) hasta uno de los estados más a la derecha (t^j, t^k) tienen el mismo valor, sea cual sea la combinación de etiquetas que forma el trigrama $t^i\,t^j\,t^k$. Se dice entonces que estas probabilidades toman *valores empatados*[10].

[10] O también *tied values*.

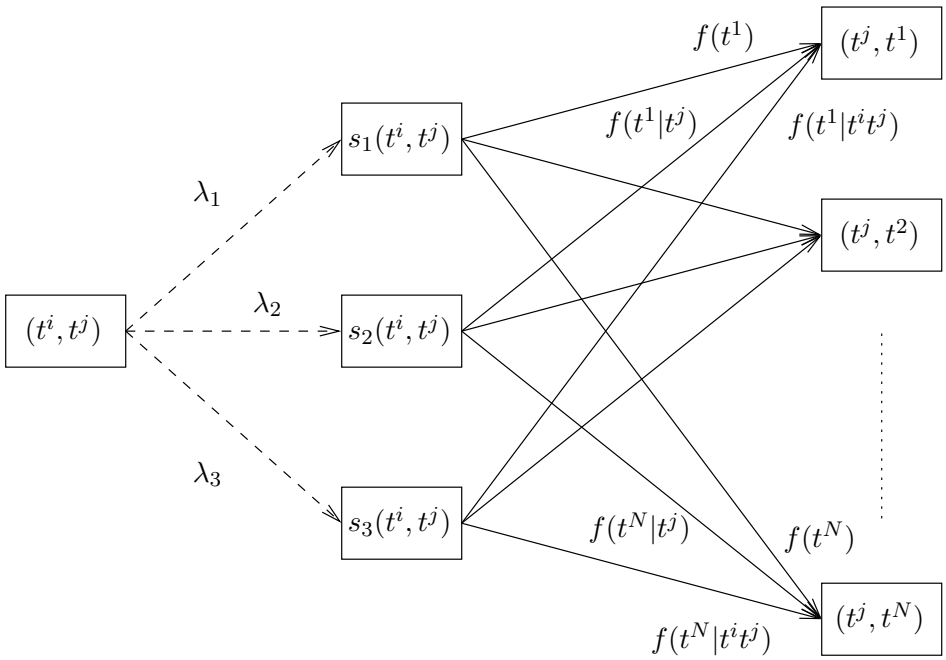

Figura 3.9: Fragmento del suavizado lineal de un HMM basado en trigramas

Pues bien, dado que hemos visto que el modelo de lenguaje al que obedece la ecuación (3.15) es un HMM, se puede utilizar el algoritmo de Baum-Welch para estimar los valores λ_i óptimos. Además, como una consecuencia favorable de que el algoritmo deba *empatar* o igualar las probabilidades λ_i, independientemente de a qué subparte del HMM pertenezcan, el proceso de estimación sólo necesita manejar tres contadores, uno para cada tipo de transición épsilon, del número esperado de veces que se cruza por una transición. Para el resto de transiciones, no se necesita establecer ningún otro tipo de contador porque de hecho las probabilidades de esas transiciones están ya fijadas de antemano. Debido a todo esto, se pueden sugerir ideas prácticas que dan lugar a cálculos en este caso más sencillos que los del algoritmo de Baum-Welch, y que por tanto simplifican aún más la obtención de los λ_i óptimos [Jelinek 1997, pp. 66-69].

Pero ahora preferimos centrar nuestro interés en responder a una importante pregunta: ¿qué tipo de datos de entrenamiento deberíamos usar para determinar los pesos λ_i? Está claro que no pueden ser los mismos datos sobre los que se calculan las frecuencias $f(\ |\ )$, porque en ese caso las estimaciones darían como resultado $\lambda_3 = 1$ y $\lambda_1 = \lambda_2 = 0$. De hecho, $f(t^k|t^i\, t^j)$ es la estimación de máxima verosimilitud de $P(t^k|t^i\, t^j)$ para los datos de entrenamiento en los que se basa dicha frecuencia $f(t^k|t^i\, t^j)$. Sin embargo, mirando de nuevo la figura 3.9, se intuye que, de los tres caminos posibles que conducen a cada uno de los estados más a la derecha, el HMM ha incluido el camino superior para poder generar la tercera etiqueta t^k, incluso aunque el bigrama $t^j\, t^k$ no haya aparecido en los datos de entrenamiento. Y de manera similar, mediante ese mismo camino superior y mediante el camino central, se hace posible la tercera etiqueta t^k, incluso aunque no exista ninguna ocurrencia del trigrama $t^i\, t^j\, t^k$. Por tanto se concluye que el conjunto total de los datos de entrenamiento debe ser dividido en dos porciones:

1. La primera, mucho más grande, denominada *datos de desarrollo*[11], se utiliza para estimar las frecuencias relativas $f(\ |\ )$.

[11] *Development data*.

2. Una vez que éstas están fijadas, la segunda porción de datos, mucho más pequeña ya que quedan por estimar muchos menos parámetros, se usa para estimar los pesos λ_i. Esta porción se denomina *datos extendidos* u *ocultos*[12].

Por supuesto, una vez que se ha realizado este proceso, el modelo obtenido se puede mejorar combinando ambas porciones de datos y reestimando las frecuencias $f(\ |\ )$. Esta técnica de suavizado lineal se denomina *interpolación de borrado*[13].

La interpolación de borrado se puede realizar también mediante una eliminación sucesiva de cada trigrama del corpus de entrenamiento, y una posterior estimación de los λ_i óptimos a partir del resto de n-gramas del corpus. Conocidos los contadores de frecuencias para unigramas, bigramas y trigramas, los pesos λ_i se pueden determinar eficientemente a través del siguiente algoritmo.

Algoritmo 3.8 Cálculo de los parámetros λ_1, λ_2 y λ_3 de un esquema de interpolación lineal, conocidas las frecuencias de unigramas, bigramas y trigramas, y conocido N, el tamaño del corpus de entrenamiento [Brants 2000]:

1. Inicializar $\lambda_1 = \lambda_2 = \lambda_3 = 0$.

2. Para cada trigrama $t_1\, t_2\, t_3$ con $C(t_1, t_2, t_3) > 0$, localizar el máximo de los tres valores siguientes y realizar la acción correspondiente:

   - $\frac{C(t_1,t_2,t_3)-1}{C(t_1,t_2)-1}$: incrementar λ_3 en $C(t_1, t_2, t_3)$ unidades.
   - $\frac{C(t_2,t_3)-1}{C(t_2)-1}$: incrementar λ_2 en $C(t_1, t_2, t_3)$ unidades.
   - $\frac{C(t_3)-1}{N-1}$: incrementar λ_1 en $C(t_1, t_2, t_3)$ unidades.

3. Normalizar los valores λ_1, λ_2 y λ_3.

Abusando un poco de la notación, con el fin de no complicar en exceso las ecuaciones con la presencia de tantos subíndices, hemos denotado el trigrama $t_{i-2}\, t_{i-1}\, t_i$ mediante $t_1\, t_2\, t_3$, donde de manera obvia los números 1, 2 y 3 hacen referencia a la posición de cada etiqueta dentro del trigrama. Si el denominador de alguna de las expresiones es 0, se define el resultado de esa expresión como 0. Restar 1 en este algoritmo es la manera de tener en cuenta los datos no observados. Sin esta resta, el modelo efectivamente sobreestimaría los datos de entrenamiento, generando $\lambda_3 = 1$ y $\lambda_1 = \lambda_2 = 0$ y produciendo peores resultados. □

Hemos visto que la ecuación (3.15) propone valores constantes para los parámetros de interpolación λ_1, λ_2 y λ_3. Es cierto que quizás no es una buena idea utilizar siempre los mismos valores, pero es cierto también que la consideración de un conjunto de valores λ_i, $i \in \{1, 2, 3\}$, para cada posible par de etiquetas eleva muchísimo el número de parámetros del modelo, lo cual no sólo no introduce ninguna mejora en relación con el fenómeno de los datos dispersos, sino que empeora el problema.

No obstante, algunos autores han sugerido que al menos sí sería conveniente una agrupación de los bigramas en un número moderado de clases y una posterior estimación de un conjunto de valores λ_i distinto para cada clase, aunque no queda claro cuál sería un buen criterio para la definición de esas clases.

Brants es quizás el único autor que proporciona datos concretos sobre diferentes experimentos de agrupación. Uno de ellos incluía un conjunto de valores λ_i distinto para cada frecuencia. Otra

[12] *Held-out data.*
[13] O también *deleted interpolation.*

de las posibilidades estudiadas fue la definición de dos clases, frecuencias altas y frecuencias bajas, a ambos extremos de la escala, y la posterior aplicación de diferentes criterios de agrupación, también basados en frecuencias, para definir las clases intermedias. Pero finalmente observó que la mayoría de los resultados eran equivalentes, obteniendo incluso peores cifras con algunas de las agrupaciones consideradas. Por esta razón, Brants utiliza en su etiquetador interpolación lineal independiente del contexto, es decir, valores constantes para los parámetros λ_i [Brants 2000].

Otros autores, sin embargo, proponen una reducción del número de parámetros a estimar mediante la especificación de que ciertos sucesos son absolutamente improbables, es decir, tienen probabilidad 0, lo cual permite introducir *ceros estructurales* en el modelo. Efectivamente, el hecho de hacer que algunos sucesos no sean posibles, por ejemplo un trigrama formado por tres preposiciones seguidas, añade gran cantidad de estructura al modelo, mejora el rendimiento del proceso de entrenamiento, y por tanto facilita en gran medida la labor de estimación de parámetros. Pero esto resulta apropiado sólo en algunas circunstancias y no con espacios de estados tan grandes.

En cualquier caso, la interpolación lineal no es la única manera de enfrentarse al problema de la poca frecuencia de determinados sucesos en los datos de entrenamiento. Existen otros métodos de estimación que, aunque son también dependientes del número de veces que aparecen los sucesos en el corpus de entrenamiento, no se basan en absoluto en frecuencias relativas. Como consecuencia, se han sugerido muchas fórmulas que son capaces de asignar probabilidades distintas de cero a los sucesos no observados, permitiendo así hacer una importante distinción entre este tipo de *ceros no observados*, y los *ceros reales* que serían los correspondientes a los sucesos efectivamente no posibles. Entre todas ellas, la más conocida es la fórmula de Good-Turing[14].

3.4.3.3 Estimación combinada mediante métodos híbridos

Los etiquetadores basados en HMM,s trabajan bien cuando se dispone de un corpus de entrenamiento suficientemente grande. A menudo éste no es el caso. Suele ocurrir con frecuencia que queremos etiquetar un texto de un dominio especializado donde las probabilidades de emisión de las palabras son diferentes de las que se pueden observar en los textos de entrenamiento. Otras veces necesitamos etiquetar textos de idiomas para los cuales simplemente no existen *corpora* etiquetados. En estos casos, hemos visto anteriormente que se puede utilizar un procedimiento de estimación no visible o no supervisado a partir de una inicialización pseudo-aleatoria de los parámetros del modelo y de la posterior aplicación del algoritmo de Baum-Welch.

Los fundamentos teóricos sugieren que el algoritmo de Baum-Welch debe detenerse cuando no se puede construir un modelo que mejore la probabilidad de la secuencia de entrenamiento dada. Sin embargo, ha sido demostrado que, para el caso de la etiquetación, este criterio a menudo produce como resultado un sobreentrenamiento del modelo. Este fenómeno ha sido estudiado en profundidad por Elworthy, quien entrenó diferentes HMM,s considerando una gran variedad de condiciones de inicialización y de distintos números de iteraciones [Elworthy 1994]:

- En ocasiones, el proceso de entrenamiento se mostraba estable y siempre producía mejoras del rendimiento después de cada iteración, demostrando que el criterio probabilístico era apropiado para esos casos.

[14] La idea intuitiva del método de estimación de Good-Turing es que, en lugar de estimar $P(X)$, intentamos estimar $P(X|C)$, donde C es una clasificación de sucesos definida *a priori* (en nuestro caso, los sucesos X que aparecen en el corpus de entrenamiento exactamente C veces). De esta manera, es más sencillo estimar $P(X)$, y en concreto se puede estimar $P(X|0)$, que es precisamente la probabilidad de los sucesos que no aparecen en el corpus. En resumen, el método de Good-Turing corrige la estimación de máxima verosimilitud en base al número de veces que algo ocurre en el corpus.

- Pero otras veces, la mejora aparecía sólo durante algunas iteraciones, normalmente 2 ó 3, y después el proceso de entrenamiento no hacía más que degradar el rendimiento.

Esto último se producía en lo que inicialmente se consideraban como los escenarios típicos de aplicación de los HMM,s: cuando se dispone de un diccionario, pero no se dispone de ningún corpus etiquetado. Por tanto, en este tipo de situaciones, los cuidados se deben extremar al máximo con el fin de no sobreentrenar el modelo. Una forma de conseguir esto es validar dicho modelo después de cada iteración sobre un conjunto de datos separado (*held-out data*), y parar el entrenamiento cuando el rendimiento empieza a decrecer.

Elworthy también confirmó los resultados encontrados por Merialdo, que demuestran que si se dipone inicialmente de un corpus etiquetado, la aplicación del algoritmo de Baum-Welch puede degradar el rendimiento ya desde la primera iteración [Merialdo 1994]. Sin embargo, una peculiaridad interesante es el hecho de que si el texto de entrenamiento y el de validación son muy diferentes, unas pocas iteraciones podrían producir mejoras. Además, esto suele ocurrir con frecuencia en la práctica, ya que a menudo tenemos que enfrentarnos con tipos de textos para los cuales no se dispone de *corpora* de entrenamiento etiquetados similares. En resumen:

- Si existe un texto de entrenamiento suficientemente grande y similar a los textos con los que se va a trabajar, entonces se debería utilizar un procedimiento de estimacion totalmente visible o supervisado.

- Si no existe ningún texto de entrenamiento disponible, o si los textos de entrenamiento y validación son muy diferentes, entonces se debería aplicar el algoritmo de Baum-Welch durante unas pocas iteraciones.

- Sólo se debería de aplicar durante un número grande de iteraciones, 10 ó más, cuando no hay ningún tipo de información léxica disponible.

Y en este último caso, no cabe esperar un buen rendimiento. Esto no se debe a ningún defecto del algoritmo de Baum-Welch, sino al hecho de que dicho algoritmo tan sólo realiza ajustes de los parámetros del HMM con el fin de maximizar la probabilidad de los datos de entrenamiento. Los cambios que realiza para reducir la entropía cruzada de esos datos podrían no estar de acuerdo con nuestro objetivo real, que es el de asignar a las palabras etiquetas pertenecientes a un conjunto predefinido. Por tanto, esta técnica no siempre es capaz de optimizar el rendimiento para la tarea particular de la etiquetación.

3.4.3.4 Integración de diccionarios

Un problema similar al de las transiciones entre estados ocurre también con las palabras. En un primer momento podemos pensar que si estamos hablando de entrenamiento puramente supervisado, las probabilidades de generación de las palabras son lo único que sí se puede estimar perfectamente. Sin embargo, en la práctica, podemos encontrarnos con palabras que no aparecen en los textos de entrenamiento, pero que quizás sí las tenemos presentes en un diccionario. Es decir, se trata de palabras para las cuales conocemos sus posibles etiquetas, pero que al no haber sido vistas durante el entrenamiento, no tienen definidas sus probabilidades de emisión. Una vez más, no resulta conveniente dejar a cero esas probabilidades.

Por tanto, se hace necesario el uso de métodos que permitan la correcta integración de la información aportada por el diccionario con los datos proporcionados por el texto de entrenamiento. Existen dos métodos generales para realizar esta integración:

- **Método *Adding One* de Church**. El método *Adding One* o método *de sumar uno* utiliza el diccionario como si se tratara de un corpus etiquetado, de manera que cada uno

de los pares palabra-etiqueta presentes en el diccionario aparece una sola vez en dicho corpus [Church 1988]. Por supuesto, este nuevo corpus se utilizará sólo para estimar las probabilidades de emisión de las palabras, pero no las probabilidades de transición entre estados, ya que el orden que siguen las palabras y las etiquetas dentro del diccionario no tiene nada que ver con el orden que siguen en las frases reales. De esta manera, para todo par (w^k, t^j) presente en el diccionario, la probabilidad de emisión se estima mediante

$$\hat{p}(w^k|t^j) = \frac{C(w^k|t^j) + 1}{C(t^j) + K_j}$$

donde K_j es el número de palabras etiquetadas con t^j que aparecen en el diccionario, mientras que para el resto de pares palabra-etiqueta que aparezcan en el corpus de entrenamiento y no en el diccionario la estimación se realiza mediante la misma ecuación, pero sin sumar 1 en el numerador. Intuitivamente, volviendo al ejemplo de las urnas y las bolas, el método opera como si todas y cada unas de las bolas o palabras del diccionario fueran colocadas en sus urnas o etiquetas correspondientes una sola vez, como paso previo a la estimación de las probabilidades de emisión. Con esto se produce el efecto deseado de que las probabilidades de emisión de las palabras del diccionario no queden a cero, incluso aunque no hayan aparecido en el corpus de entrenamiento.

- **Método de Good-Turing**. Como ya hemos comentado anteriormente, éste es un método de estimación que no está basado en frecuencias relativas, pero que también es capaz de asignar probabilidades distintas de cero a los sucesos no observados. En este contexto, un suceso posible pero no observado es cualquier par palabra-etiqueta que aparece en el diccionario y no aparece en el corpus de entrenamiento (cero no observado), mientras que un suceso no posible es cualquier par palabra-etiqueta que no aparece ni en el diccionario ni en el corpus de entrenamiento (cero real).

Es importante recordar que el uso de un diccionario externo puede ayudar a incrementar el rendimiento del proceso de etiquetación.

3.4.3.5 Tratamiento de palabras desconocidas

Hemos visto anteriormente cómo estimar las probabilidades de emisión para las palabras que aparecen o bien en el corpus, o bien en nuestro diccionario, o bien en ambos. Pero es seguro que al intentar etiquetar nuevas frases encontraremos multitud de palabras que no han aparecido previamente en ninguno de esos recursos. Hemos visto también que un conocimiento *a priori* de la distribución de etiquetas de una palabra, o al menos de la proporción para la etiqueta más probable, supone una gran ayuda para la etiquetación. Esto significa que las palabras desconocidas son el mayor problema de los etiquetadores, y en la práctica la diferencia de rendimiento entre unos y otros puede ser debida a la proporción de palabras desconocidas y al procedimiento de adivinación y tratamiento de las mismas que cada etiquetador tenga integrado.

La manera más simple de enfrentarse a este problema es suponer que toda palabra desconocida puede pertenecer a cualquier categoría gramatical, o quizás a una clase de categorías *abiertas*, por ejemplo, sustantivos, adjetivos, verbos, etc., pero no preposiciones, ni artículos, ni pronombres, que suponemos que pertenecen a otra clase de categorías *cerradas* y que todas las palabras correspondientes a ellas son conocidas y están ya en el diccionario. Aunque esta aproximación podría ser válida en algunos casos, en general, el no hacer uso de la información léxica de las palabras (prefijos, sufijos, etc.) para proponer un conjunto más limitado de posibles etiquetas degrada mucho el rendimiento de los etiquetadores. Es por ello que existen numerosos trabajos orientados a explorar este tipo de características, y mejorar así la estimación de las probabilidades de emisión para las palabras desconocidas:

- Por ejemplo, Weischedel estima las probabilidades de generación de las palabras en base a tres tipos de información: la probabilidad de que una categoría genere una palabra desconocida[15], la probabilidad de que una categoría genere una palabra cuya inicial es mayúscula o minúscula, y la probabilidad de generación de sufijos particulares:

$$\hat{p}(w^k|t^j) = \frac{1}{Z}\, P(\text{desconocida}|t^j)\; P(\text{mayúscula}|t^j)\; P(\text{sufijo}|t^j)$$

  donde Z es una constante de normalización. Este modelo reduce la proporción de error de palabaras desconocidas de más de un 40% a menos de un 20% [Weischedel *et al.* 1993]. Charniak propuso un modelo alternativo que utiliza tanto las raíces como los sufijos [Charniak *et al.* 1993].

- La mayor parte del trabajo que se realiza en relación con las palabras desconocidas asume que las propiedades consideradas son independientes. Dicha independencia no siempre es una buena suposición. Por ejemplo, las palabras en mayúsculas tienen más probabilidad de ser desconocidas, y por tanto las propiedades *mayúscula* y *desconocida* del modelo de Weischedel no son realmente independientes. Franz desarrolló un modelo que tiene en cuenta este tipo de dependencias [Franz 1996, Franz 1997].

- Actualmente, el método de manejo de palabras desconocidas que parece ofrecer mejores resultados para los lenguajes flexivos es el análisis de sufijos mediante aproximaciones basadas en inferencias Bayesianas [Samuelsson 1993]. En este método, las probabilidades de las etiquetas propuestas para las palabras no presentes en el diccionario se eligen en función de las terminaciones de dichas palabras. La distribución de probabilidad para un sufijo particular se genera a partir de todas las palabras del corpus de entrenamiento que comparten ese mismo sufijo. El término sufijo tal y como se utiliza aquí significa *secuencia final de caracteres de una palabra*, lo cual no coincide necesariamente con el significado lingüístico de sufijo. Por esta razón, el método requiere una definición previa de la longitud máxima de sufijos que se va a considerar.

  Las probabilidades se suavizan mediante un procedimiento de abstracción sucesiva. Esto permite calcular $P(t|l_{n-m+1}, \ldots, l_n)$, la probabilidad de una etiqueta t dadas las últimas m letras l_i de una palabra, a través de una secuencia de contextos más generales que omite un caracter del sufijo en cada iteración, de forma que la suavización se lleva a cabo en base a $P(t|l_{n-m+2}, \ldots, l_n)$, $P(t|l_{n-m+3}, \ldots, l_n)$, $\ldots$, $P(t)$. La fórmula de la recursión es:

$$P(t|l_{n-i+1}, \ldots, l_n) = \frac{\hat{p}(t|l_{n-i+1}, \ldots, l_n) + \theta_i\, P(t|l_{n-i+2}, \ldots, l_n)}{1 + \theta_i}$$

  para $i = m, \ldots, 1$, utilizando la estimación de máxima verosimilitud para un sufijo de longitud i calculada a partir de las frecuencias del corpus de entrenamiento como

$$\hat{p}(t|l_{n-i+1}, \ldots, l_n) = \frac{C(t, l_{n-i+1}, \ldots, l_n)}{C(l_{n-i+1}, \ldots, l_n)},$$

  utilizando también unos determinados pesos de suavización θ_i, y utilizando como caso base $P(t) = \hat{p}(t)$. Por supuesto, para el modelo de Markov, necesitamos las probabilidades condicionadas inversas $P(l_{n-i+1}, \ldots, l_n|t)$, las cuales se obtienen por la regla de Bayes.

  Como se puede ver, la definición de este método no es rigurosa en todos y cada uno de sus aspectos, lo cual da lugar a diferentes interpretaciones a la hora de aplicarlo. Por ejemplo:

[15] Esta probabilidad puede ser cero para algunas categorías, como por ejemplo las preposiciones.

- Es necesario identificar un buen valor para m, la longitud máxima utilizada para los sufijos. Brants elige para su etiquetador el criterio de que m depende de cada palabra en cuestión [Brants 2000], y utiliza para dicha palabra el sufijo más largo de entre todos los que hayan sido observados al menos una vez en el corpus de entrenamiento, pero como máximo $m = 10$ caracteres.
- Brants utiliza también una elección independiente del contexto para los pesos de suavización de sufijos θ_i, al igual que hacía con los parámetros de interpolación lineal de trigramas λ_i. Es decir, en lugar de calcular los θ_i tal y como propuso Samuelsson, a partir de la desviación estándar de las probabilidades de máxima verosimilitud de los sufijos, Brants asigna a todos los θ_i la desviación estándar de las probabilidades de máxima verosimilitud no condicionadas de las etiquetas en el corpus de entrenamiento:

$$\theta_i = \frac{1}{s-1}\sum_{j=1}^{s}(\hat{p}(t^j) - \bar{P})^2$$

  para todo $i = m, \ldots, 1$, donde s es el cardinal del conjunto de etiquetas utilizado, y la media $\bar{P}$ se calcula como

$$\bar{P} = \frac{1}{s}\sum_{j=1}^{s}\hat{p}(t^j).$$

- Otro grado de libertad del método es el que concierne a la elección de las palabras del corpus de entrenamiento que se utilizan para la extracción de los sufijos. ¿Deberíamos utilizar todas las palabras, o algunas son más adecuadas que otras? Dado que las palabras desconocidas son probablemente las más infrecuentes, se puede argumentar que el uso de los sufijos de las palabras menos frecuentes del corpus constituye una aproximación mejor para las palabras desconocidas que los sufijos de las palabras frecuentes. Brants, por tanto, realiza la extracción de sufijos sólo sobre aquellas palabras cuya frecuencia sea menor o igual que un cierto umbral de corte, y fija dicho umbral empíricamente en 10 apariciones. Además, mantiene dos pruebas de sufijos separadas, en función de si la inicial de la palabra es mayúscula o minúscula.

En general, para las palabras desconocidas, $P(w|t) = 0$ estrictamente hablando. En caso contrario, la palabra no sería desconocida. Pero tal y como hemos dicho, una de las principales habilidades que debe incluir un buen etiquetador es asignar una probabilidad $P(w|t)$ distinta de cero para las palabras no presentes en el diccionario. La única restricción que hay que respetar es que, para toda etiqueta t del conjunto de etiquetas, debería cumplirse

$$\sum_{w} P(w|t) = 1, \tag{3.16}$$

sobre todas las palabras w: las conocidas y las, en teoría, posiblemente desconocidas. Ésta es la clave del problema, porque implica que deberíamos conocer *a priori* todas las palabras desconocidas. En la práctica, esto no es así, y por tanto no conocemos completamente el conjunto de las probabilidades que estamos sumando. Una forma de afrontar el problema es considerar que no todas las palabras desconocidas juegan el mismo papel. Algunas de ellas serán efectivamente palabras nuevas para las cuales queremos probabilidades de emisión distintas de cero, pero otras podrían ser palabras con errores ortográficos para las cuales queremos probabilidades igual a cero o, en todo caso, las probabilidades de las correspondientes palabras corregidas.

Así pues, si el conjunto de palabras que van a ser aceptadas como desconocidas es *de alguna manera* conocido, entonces se puede dar un significado a la probabilidad $P(w|t)$, ya que la

restricción (3.16) podría ser calculada y verificada. Si esta restricción se respeta, entonces podemos elegir la definición de $P(w|t)$ que queramos, y una definición basada en la morfología es, por supuesto, una buena elección. En otras palabras, definir $P(w|t)$ mediante $P(\mathit{sufijo}(w)|t)$ para las palabras desconocidas es una buena idea siempre que se cumpla la restricción (3.16).

Para ello, se podrían combinar las probabilidades de los sufijos con las probabilidades de emisión de las palabras conocidas, reservando una parte de la masa de probabilidad de éstas últimas. Es decir, si conocida la etiqueta t y para toda palabra w del diccionario,

$$S = \sum_{w} P(w|t),$$

donde $S < 1$, entonces $1 - S$ sería la masa de probabilidad dedicada a las palabras desconocidas, conocida t. $P(\mathit{sufijo}|t)$ debería ser una distribución de probabilidad, de tal forma que

$$\sum_{\mathit{sufijo}} P(\mathit{sufijo}|t) = 1, \tag{3.17}$$

para toda etiqueta t del conjunto de etiquetas utilizado. Y los sufijos deberían estar correctamente definidos, de tal manera que la función $\mathit{sufijo}(w)$ fuera una aplicación. Es decir, el sufijo de w debería ser único para cada palabra w. De esta forma, $P(w|t)$ se define para las palabras desconocidas como

$$P(w|t) = (1 - S)\, P(\mathit{sufijo}(w)|t),$$

lo cual no sólo es una definición formal, sino también sensible a las propiedades morfológicas de cada palabra. Las dificultades, por supuesto, radican en la identificación de los sufijos válidos para las palabras y en la estimación de un buen valor para S.

Tal y como vimos antes, la implementación que hace Brants del método de Samuelsson no mezcla las probabilidades de los sufijos con las probabilidades de las palabras conocidas, y por tanto no respeta la restricción (3.16). Sin embargo, dicho método construye un conjunto de probabilidades de emisión distinto para cada longitud de sufijo, y cada uno de esos conjuntos verifica la restricción (3.17). Como se puede apreciar, el enfoque es totalmente distinto, pero el método también genera probabilidades directamente utilizables por los modelos de Markov.

En definitiva, el tratamiento de palabras desconocidas[16] representa el punto más débil de la aplicación de los HMM,s al proceso de etiquetación del lenguaje natural, y no se incluye normalmente en el estado del arte de los HMM,s. En esta sección hemos esbozado sólo algunos de los métodos de tratamiento de palabras desconocidas que han sido desarrollados e integrados formalmente dentro del marco de los HMM,s.

3.5 Variantes de implementación de los HMM,s

Las predicciones condicionadas sobre una historia o contexto de gran longitud no son siempre una buena idea. Por ejemplo, normalmente no existen dependencias sintácticas entre las palabras que aparecen antes y después de las comas. Por tanto, el conocimiento de la etiqueta que aparece antes de una coma no siempre ayuda a determinar correctamente la que aparece después. De hecho, ante este tipo de casos, un etiquetador basado en trigramas podría hacer predicciones peores que otro basado en bigramas, debido una vez más al fenómeno de los datos dispersos[17]. La técnica de interpolación lineal de las probabilidades de los unigramas, bigramas y trigramas

[16] También denominado *word guessing*.

[17] Muchas veces, las probabilidades de transición de los trigramas se estiman en base a sucesos de rara aparición, y por tanto la posibilidad de obtener estimaciones malas es mayor.

presentada en las secciones anteriores, es una de las aproximaciones que trata de paliar este problema, pero no es la única.

Algunos autores han optado por aumentar de manera selectiva un modelo de Markov de orden bajo, tomando como base para ello el análisis de los errores cometidos y algún otro tipo de conocimiento lingüístico previo. Por ejemplo, Kupiec observó que un HMM de orden 1 se equivocaba sistemáticamente al etiquetar la secuencia de palabras `the bottom of` como artículo-adjetivo-preposición. Entonces extendió el modelo con una red especial para esta construcción, con el propósito de que el etiquetador pudiera aprender la imposibilidad de que una preposición siga a la secuencia artículo-adjetivo [Kupiec 1992]. En general, este método selecciona manualmente determinados estados del modelo y aumenta su orden, para casos donde la *memoria* de orden 1 no es suficiente.

Otro método relacionado es el de los Modelos de Markov de memoria variable o VMMM,s[18] [Schütze y Singer 1994, Triviño y Morales 2000]. Los VMMM,s presentan estados de diferentes *longitudes*, en lugar de los estados de *longitud fija* de los etiquetadores basados en bigramas o en trigramas. Un VMMM podría transitar desde un estado que recuerda las dos últimas etiquetas (correspondiente, por tanto, a un trigrama) a un estado que recuerda las tres últimas etiquetas (correspondiente a un cuatrigrama) y después a otro estado sin memoria (correspondiente a un unigrama). El número de símbolos a recordar para una determinada secuencia se determina durante el proceso de entrenamiento, en base a criterios teóricos. En contraste con la interpolación lineal, los VMMM,s condicionan la longitud de memoria utilizada durante la predicción a la secuencia actual, en lugar de considerar una suma ponderada fija para todas las secuencias. Los VMMM,s se construyen con estrategias descendentes mediante métodos de división de estados[19]. Una posible alternativa es construirlos con estrategias ascendentes mediante métodos de fusión de modelos[20] [Stolcke y Omohundro 1994, Brants 1998].

Otra aproximación que resulta todavía más potente es la constituida por los modelos de Markov jerárquicos no emisores [Ristad y Thomas 1997]. Mediante la introducción de transiciones sin emisiones[21], estos modelos pueden almacenar también dependencias de longitud arbitraria entre los estados.

3.6 Otras aplicaciones de los HMM,s

La teoría matemática relativa a los HMM,s fue desarrollada por Baum y sus colaboradores a finales de los años sesenta y principios de los setenta [Baum *et al.* 1970]. Los HMM,s se aplicaron al procesamiento de la voz o reconocimiento del discurso hablado[22] en los años setenta por Baker [Baker 1975], y por Jelinek y sus colegas de IBM [Jelinek *et al.* 1975, Jelinek 1976]. Fue posteriormente cuando los HMM,s se utilizaron para modelizar otros aspectos de los lenguajes humanos, tales como el proceso de etiquetación.

Dentro del contexto del reconocimiento de voz, existen muy buenas referencias sobre los HMM,s y sus algoritmos [Levinson *et al.* 1983, Charniak 1993, Jelinek 1997]. Particularmente conocidas son también [Rabiner 1989, Rabiner y Juang 1993]. Todas ellas estudian en detalle tanto los HMM,s continuos, donde la salida es un valor real, como los HMM,s discretos que nosotros hemos considerado aquí. Aunque se centran en la aplicación de los HMM,s al reconocimiento de voz, resulta también muy recomendable su consulta para la obtención de

[18] *Variable Memory Markov Models.*
[19] *State splitting.*
[20] *Model merging.*
[21] Transiciones entre estados que no emiten ninguna palabra o que, de manera equivalente, emiten la palabra vacía ϵ.
[22] *Speech recognition.*

directrices y de otras muchas referencias acerca del desarrollo y uso general de los HMM,s.

En este capítulo, hemos asumido en todo momento que la arquitectura de nuestro HMM era fija, y hemos centrado la discusión en torno al problema de la obtención de los parámetros óptimos para esa arquitectura. Sin embargo, ¿cuál es la forma y el tamaño que deberíamos elegir para nuestros HMM,s cuando nos enfrentamos a un nuevo problema? Normalmente, como en el caso de la etiquetación, es la naturaleza del problema la que determina de alguna manera la arquitectura del modelo. Para circunstancias en las que no es ese el caso, existen trabajos que estudian la construcción automática de la estructura de los HMM,s. Dichos trabajos se basan en el principio de intentar encontrar el HMM más compacto posible que describa adecuadamente los datos [Stolcke y Omohundro 1993].

Los HMM,s han sido también ampliamente utilizados en aplicaciones bioinformáticas para el análisis de secuencias de genes [Baldi y Brunak 1998, Durbin *et al.* 1998]. Es cierto que puede parecer increíble que el manejo de un alfabeto de sólo cuatro símbolos, las bases nitrogenadas del ADN, entrañe grandes dificultades, pero la bioinformática es un dominio perfectamente establecido, y en el que efectivamente se plantean problemas muy serios que pueden requerir el uso de modelizaciones complejas.

Y quizás la aplicación más reciente de los HMM,s dentro del marco del procesamiento de lenguaje natural es su uso directo como motor de búsqueda en sistemas de recuperación de información [Miller *et al.* 1999]. La idea básica de esta aproximación consiste una vez más en considerar la unión de todas las palabras que aparecen en el corpus como el conjunto de símbolos de salida del modelo, e identificar un estado distinto, en este caso no para cada etiqueta, sino para cada uno de los posibles mecanismos de generación de palabras en las consultas: términos temáticos, términos dependientes del documento, palabras que aparecen frecuentemente en las consultas, mecanismos de sinonimia, etc. Posteriormente, se construye un sencillo HMM individual para cada documento, a través del cual se puede calcular la probabilidad de que dicho documento genere las palabras involucradas en la consulta que efectúa el usuario. Esa probabilidad indica si el documento es relevante o no, y en función de ella se establece la lista ordenada de documentos que el sistema muestra al usuario como respuesta a su consulta. Los resultados obtenidos con esta técnica son muy prometedores, y refuerzan la perspectiva de que los HMM,s continúan siendo aplicables incluso en temas de verdadera actualidad como es el de la recuperación de información.

Capítulo 4

Aprendizaje de etiquetas basado en transformaciones

Tradicionalmente, en lo que se refiere a la etiquetación de textos en lenguaje natural, y tal y como hemos visto en el capítulo anterior, se han preferido las aproximaciones puramente estocásticas frente a las aproximaciones basadas en reglas, debido a su buen rendimiento y sobre todo a sus facilidades de entrenamiento automático. Sin embargo, hemos visto también que algunas de las hipótesis de funcionamiento de los modelos de Markov no se adaptan del todo bien a las propiedades sintácticas de los lenguajes naturales. Debido a esto, inmediatamente surge la idea de utilizar modelos más sofisticados. Podríamos pensar por ejemplo en establecer condiciones que relacionen las nuevas etiquetas, no sólo con las etiquetas precedentes, sino también con las palabras precedentes. Podríamos pensar también en utilizar un contexto mayor que el de los etiquetadores basados en trigramas. Pero la mayoría de estas aproximaciones no tienen cabida dentro de los modelos de Markov, debido a la carga computacional que implican y a la gran cantidad de nuevos parámetros que necesitaríamos estimar. Incluso con los etiquetadores basados en trigramas hemos visto que es necesario aplicar técnicas de suavización e interpolación, ya que la estimación de máxima verosimilitud por sí sola no es lo suficientemente robusta.

Eric Brill presentó un sistema de etiquetación basado en reglas, el cual, a partir de un corpus de entrenamiento, infiere automáticamente las reglas de transformación [Brill 1993b], salvando así la principal limitación de este tipo de técnica que es precisamente el problema de cómo obtener dichas reglas. El etiquetador de Brill alcanza un rendimiento comparable al de los etiquetadores estocásticos y, a diferencia de éstos, la información lingüística no se captura de manera indirecta a través de grandes tablas de probabilidades, sino que se codifica directamente bajo la forma de un pequeño conjunto de reglas no estocásticas muy simples, pero capaces de representar interdependencias muy complejas entre palabras y etiquetas. Este capítulo describe las características principales del etiquetador de Brill y de su principio de funcionamiento: un paradigma de aprendizaje basado en transformaciones y dirigido por el error[1]. Veremos que este método es capaz de explorar un abanico mayor de propiedades, tanto léxicas como sintácticas, de los lenguajes naturales. En particular, se pueden relacionar etiquetas con palabras concretas, se puede ampliar el contexto precedente, e incluso se puede utilizar el contexto posterior.

4.1 Arquitectura interna del etiquetador de Brill

El etiquetador de Brill consta de tres partes, que se infieren automáticamente a partir de un corpus de entrenamiento: un etiquetador léxico, un etiquetador de palabras desconocidas, y un

[1] *Transformation-based error-driven learning.*

etiquetador contextual. A continuación se describe detalladamente cada una de ellas.

4.1.1 El etiquetador léxico

El etiquetador léxico etiqueta inicialmente cada palabra con su etiqueta más probable, sin tener en cuenta el contexto en el que dicha palabra aparece. Dicha etiqueta más probable se estima previamente mediante el estudio del corpus de entrenamiento. A las palabras desconocidas se les asigna en un primer momento la etiqueta correspondiente a sustantivo propio si la primera letra es mayúscula, o la correspondiente a sustantivo común en otro caso. Posteriormente, el etiquetador de palabras desconocidas aplica en orden una serie de reglas de transformación léxicas.

Si se dispone de un diccionario previamente construido, es posible utilizarlo junto con el que el etiquetador de Brill genera automáticamente. Más adelante veremos cómo se realiza esta integración y en qué circunstancias concretas este proceso ayuda a mejorar el rendimiento del etiquetador.

4.1.2 El etiquetador de palabras desconocidas

El etiquetador de palabras desconocidas opera justo después de que el etiquetador léxico haya etiquetado todas las palabras presentes en el diccionario, y justo antes de que se apliquen las reglas contextuales. Este módulo intenta *adivinar* una etiqueta para una palabra desconocida en función de su sufijo[2], de su prefijo, y de otras propiedades relevantes similares.

Básicamente, cada transformación consta de dos partes: una descripción del contexto de aplicación, y una regla de reescritura que reemplaza una etiqueta por otra. La plantilla genérica de transformaciones léxicas es la siguiente:

- `x haspref l A`: si los primeros `l` caracteres de la palabra son `x`, se asigna a la palabra desconocida la etiqueta `A`
- `A x fhaspref l B`: si la etiqueta actual de la palabra es `A` y sus primeros `l` caracteres son `x`, se cambia dicha etiqueta por `B`
- `x deletepref l A`: si borrando el prefijo `x` de longitud `l` obtenemos una palabra conocida, se asigna a la palabra desconocida la etiqueta `A`
- `A x fdeletepref l B`: si la etiqueta actual de la palabra es `A` y borrando el prefijo `x` de longitud `l` obtenemos una palabra conocida, se cambia dicha etiqueta por `B`
- `x addpref l A`: si añadiendo el prefijo `x` de longitud `l` obtenemos una palabra conocida, se asigna a la palabra desconocida la etiqueta `A`
- `A x faddpref l B`: si la etiqueta actual de la palabra es `A` y añadiendo el prefijo `x` de longitud `l` obtenemos una palabra conocida, se cambia dicha etiqueta por `B`
- `x hassuf l A`: si los últimos `l` caracteres de la palabra son `x`, se asigna a la palabra desconocida la etiqueta `A`
- `A x fhassuf l B`: si la etiqueta actual de la palabra es `A` y sus últimos `l` caracteres son `x`, se cambia dicha etiqueta por `B`
- `x deletesuf l A`: si borrando el sufijo `x` de longitud `l` obtenemos una palabra conocida, se asigna a la palabra desconocida la etiqueta `A`
- `A x fdeletesuf l B`: si la etiqueta actual de la palabra es `A` y borrando el sufijo `x` de longitud `l` obtenemos una palabra conocida, se cambia dicha etiqueta por `B`

[2]Por ejemplo, en inglés, una palabra terminada en `ing` podría etiquetarse como un verbo en gerundio.

`x addsuf l A`: si añadiendo el sufijo `x` de longitud `l` obtenemos una palabra conocida, se asigna a la palabra desconocida la etiqueta `A`

`A x faddsuf l B`: si la etiqueta actual de la palabra es `A` y añadiendo el sufijo `x` de longitud `l` obtenemos una palabra conocida, se cambia dicha etiqueta por `B`

`w goodright A`: si la palabra aparece inmediatamente a la derecha de la palabra `w`, se asigna a la palabra desconocida la etiqueta `A`

`A w fgoodright B`: si la etiqueta actual de la palabra es `A` y aparece inmediatamente a la derecha de la palabra `w`, se cambia dicha etiqueta por `B`

`w goodleft A`: si la palabra aparece inmediatamente a la izquierda de la palabra `w`, se asigna a la palabra desconocida la etiqueta `A`

`A w fgoodleft B`: si la etiqueta actual de la palabra es `A` y aparece inmediatamente a la izquierda de la palabra `w`, se cambia dicha etiqueta por `B`

`z char A`: si el caracter `z` aparece en la palabra, se asigna a la palabra desconocida la etiqueta `A`

`A z fchar B`: si la etiqueta actual de la palabra es `A` y el caracter `z` aparece en la palabra, se cambia dicha etiqueta por `B`

donde `A` y `B` son variables sobre el conjunto de todas las etiquetas, `x` es cualquier cadena de caracteres de longitud 1, 2, 3 o 4, `l` es la longitud de dicha cadena, `w` es cualquier palabra, y `z` es cualquier caracter.

Ejemplo 4.1 A continuación se muestran algunas de las reglas de transformación léxicas más comunes que el etiquetador de Brill encontró para el español:

`rse hassuf 3 V000f0PE1`: si los últimos `3` caracteres de la palabra son `rse`, se asigna a la palabra desconocida la etiqueta `V000f0PE1`, es decir, verbo infinitivo con un pronombre enclítico

`r hassuf 1 V000f0`: si el último caracter de la palabra es `r`, se asigna a la palabra desconocida la etiqueta `V000f0`, es decir, verbo infinitivo

`V000f0 or fhassuf 2 Scms`: si la etiqueta actual de la palabra es `V000f0`, es decir, verbo infinitivo, y sus últimos `2` caracteres son `or`, se cambia dicha etiqueta por la etiqueta `Scms`, es decir, sustantivo común, masculino, singular

`ría deletesuf 3 Vysci0`: si borrando el sufijo `ría` de longitud `3` obtenemos una palabra conocida, se asigna a la palabra desconocida la etiqueta `Vysci0`, es decir, verbo, primera y tercera personas del singular, postpretérito de indicativo

`Scfs r faddsuf 1 V3spi0`: si la etiqueta actual de la palabra es `Scfs`, es decir, sustantivo, común, femenino, singular, y añadiendo el sufijo `r` de longitud `1` obtenemos una palabra conocida, se cambia dicha etiqueta por la etiqueta `V3spi0`, es decir, verbo, tercera persona del singular, presente de indicativo

`el goodright Scms`: si la palabra aparece inmediatamente a la derecha de la palabra `el`, se asigna a la palabra desconocida la etiqueta `Scms`, es decir, sustantivo común, masculino, singular

`Scmp las fgoodright Scfp`: si la etiqueta actual de la palabra es `Scmp`, es decir, sustantivo común, masculino, plural, y aparece inmediatamente a la derecha de la palabra `las`, se cambia dicha etiqueta por la etiqueta `Scfp`, es decir, sustantivo común femenino, plural

`% goodleft Ncyyp`: si la palabra aparece inmediatamente a la izquierda de la palabra `%`, se asigna a la palabra desconocida la etiqueta `Ncyyp`, es decir, numeral cardinal, determinante y no determinante, masculino y femenino, plural

`w char Ze00`: si el caracter `w` aparece en la palabra, se asigna a la palabra desconocida la etiqueta `Ze00`, es decir, palabra extranjera

Esas reglas fueron generadas por el etiquetador de Brill después de ser entrenado con una porción de texto en español procedente del corpus ITU[3]. □

Por debajo del formato general de las reglas léxicas propuestas por Brill subyace un estudio lingüístico muy importante. Es por ello que esta plantilla genérica de transformaciones léxicas representa una manera muy elegante de integrar el manejo de palabras desconocidas dentro de una herramienta general de etiquetación, y la hace independiente del idioma a tratar. Pero considerando el caso concreto del español, se echan de menos fenómenos muy comunes tales como el sufijo `mente` para formar adverbios a partir de los adjetivos. En el corpus ITU existe un buen número de palabras que presentan dicha característica, pero ésta nunca podrá aparecer reflejada en una regla debido a la limitación de 4 caracteres de longitud en los prefijos y sufijos de las reglas extraídas automáticamente. No obstante, el etiquetador de Brill proporciona al usuario la posibilidad de añadir manualmente nuevas reglas después del entrenamiento.

Otras características relevantes para el tratamiento de palabras desconocidas en modelos de etiquetación basados en reglas fueron estudiadas por Mikheev, quien no sólo amplía el formalismo de reglas léxicas del etiquetador de Brill, sino que también propone su propio algoritmo para la inducción automática de dichas reglas [Mikheev 1997].

4.1.3 El etiquetador contextual

El etiquetador contextual actúa justo después del etiquetador de palabras desconocidas, aplicando en orden una secuencia de reglas contextuales que, al igual que las léxicas, también han sido previamente inferidas de manera automática a partir del corpus de entrenamiento. La plantilla genérica de transformaciones contextuales es la siguiente:

`A B prevtag C`: cambiar la etiqueta `A` por `B` si la palabra anterior aparece etiquetada con la etiqueta `C`

`A B prev1or2tag C`: cambiar la etiqueta `A` por `B` si una de las dos palabras anteriores aparece etiquetada con la etiqueta `C`

`A B prev1or2or3tag C`: cambiar la etiqueta `A` por `B` si una de las tres palabras anteriores aparece etiquetada con la etiqueta `C`

`A B prev2tag C`: cambiar la etiqueta `A` por `B` si la segunda palabra anterior aparece etiquetada con la etiqueta `C`

`A B nexttag C`: cambiar la etiqueta `A` por `B` si la palabra siguiente aparece etiquetada con la etiqueta `C`

`A B next1or2tag C`: cambiar la etiqueta `A` por `B` si una de las dos palabras siguientes aparece etiquetada con la etiqueta `C`

`A B next1or2or3tag C`: cambiar la etiqueta `A` por `B` si una de las tres palabras siguientes aparece etiquetada con la etiqueta `C`

`A B next2tag C`: cambiar la etiqueta `A` por `B` si la segunda palabra siguiente aparece etiquetada con la etiqueta `C`

[3] *International Telecommunications Union CCITT Handbook.*

- `A B prevbigram C D`: cambiar la etiqueta `A` por `B` si la palabra anterior aparece etiquetada con la etiqueta `C` y la segunda palabra anterior con `D`
- `A B nextbigram C D`: cambiar la etiqueta `A` por `B` si la palabra siguiente aparece etiquetada con la etiqueta `C` y la segunda palabra siguiente con `D`
- `A B surroundtag C D`: cambiar la etiqueta `A` por `B` si la palabra anterior aparece etiquetada con la etiqueta `C` y la siguiente con `D`
- `A B curwd w`: cambiar la etiqueta `A` por `B` si la palabra actual es `w`
- `A B prevwd w`: cambiar la etiqueta `A` por `B` si la palabra anterior es `w`
- `A B prev1or2wd w`: cambiar la etiqueta `A` por `B` si una de las dos palabra anteriores es `w`
- `A B prev2wd w`: cambiar la etiqueta `A` por `B` si la segunda palabra anterior es `w`
- `A B nextwd w`: cambiar la etiqueta `A` por `B` si la palabra siguiente es `w`
- `A B next1or2wd w`: cambiar la etiqueta `A` por la etiqueta `B` si una de las dos palabras siguientes es `w`
- `A B next2wd w`: cambiar la etiqueta `A` por `B` si la segunda palabra siguiente es `w`
- `A B lbigram w x`: cambiar la etiqueta `A` por `B` si las dos palabras anteriores son `w` y `x`
- `A B rbigram w x`: cambiar la etiqueta `A` por `B` si las dos palabras siguientes son `w` y `x`
- `A B wdand2bfr x w`: cambiar la etiqueta `A` por `B` si la palabra actual es `w` y la segunda palabra anterior es `x`
- `A B wdand2aft w x`: cambiar la etiqueta `A` por `B` si la palabra actual es `w` y la segunda palabra siguiente es `x`
- `A B wdprevtag C w`: cambiar la etiqueta `A` por `B` si la palabra actual es `w` y la anterior aparece etiquetada con la etiqueta `C`
- `A B wdnexttag w C`: cambiar la etiqueta `A` por `B` si la palabra actual es `w` y la siguiente aparece etiquetada con la etiqueta `C`
- `A B wdand2tagbfr C w`: cambiar la etiqueta `A` por `B` si la palabra actual es `w` y la segunda palabra anterior aparece etiquetada con la etiqueta `C`
- `A B wdand2tagaft w C`: cambiar la etiqueta `A` por `B` si la palabra actual es `w` y la segunda palabra siguiente aparece etiquetada con la etiqueta `C`

donde `A`, `B`, `C` y `D` son variables sobre el conjunto de todas las etiquetas, y `w` y `x` son cualquier palabra. La figura 4.1 resume gráficamente los posibles contextos que se pueden tener en cuenta a la hora de aplicar una transformación. La palabra a etiquetar es siempre la de la posición i, que aparece marcada con un asterisco. Los recuadros indican cuáles son las posiciones relevantes de cada esquema contextual. Si en una posición dada aparece un recuadro normal, el esquema considera la etiqueta de la palabra que está en esa posición. Si aparece un recuadro sombreado, el esquema considera la palabra concreta. Por ejemplo, la regla `A B prevbigram C D` responde al esquema 3, mientras que la regla `A B lbigram w x` utiliza el esquema 15.

Ejemplo 4.2 A continuación se muestran algunas de las reglas de transformación contextuales más comunes que el etiquetador de Brill encontró para el español, también a partir de una porción de texto del corpus ITU:

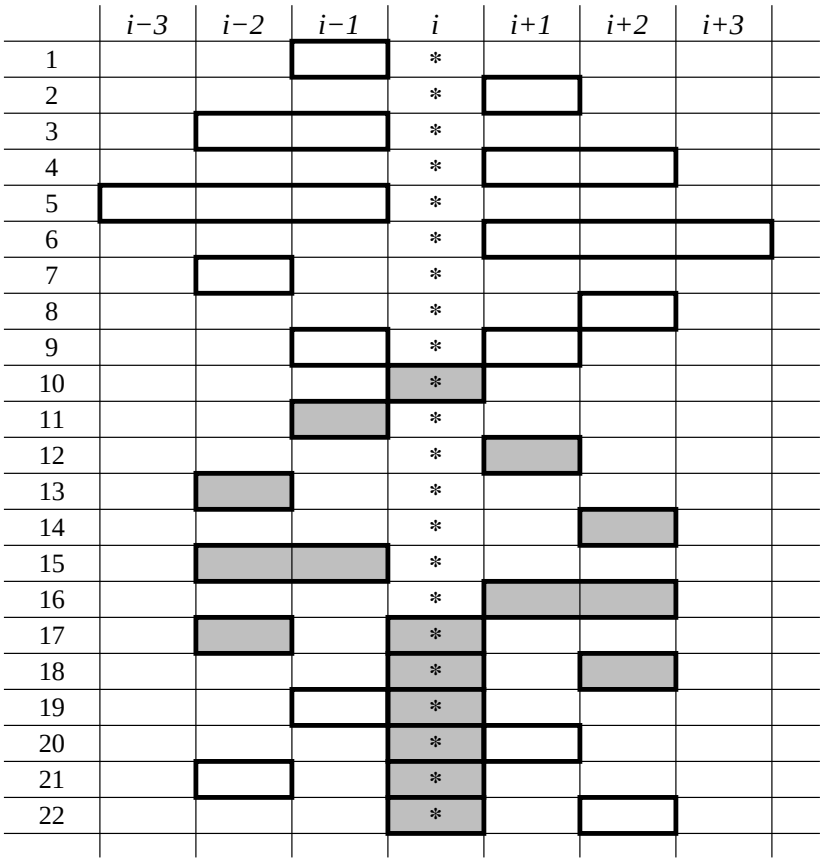

Figura 4.1: Esquemas contextuales de las reglas del etiquetador de Brill

`Afp0 Amp0 prevtag Scmp`: cambiar la etiqueta `Afp0`, es decir, adjetivo, femenino, plural, sin grado, por `Amp0`, es decir, adjetivo, masculino, plural, sin grado, si la palabra anterior aparece etiquetada con la etiqueta `Scmp`, es decir, sustantivo común, masculino, plural

`Scms Ams0 wdprevtag Scms receptor`: cambiar la etiqueta `Scms`, es decir, sustantivo común, masculino, singular, por `Ams0`, es decir, adjetivo, masculino, singular, sin grado, si la palabra actual es `receptor` y la anterior aparece etiquetada con la etiqueta `Scms`

`Scms Ams0 wdand2bfr el transmisor`: cambiar la etiqueta `Scms`, es decir, sustantivo común, masculino, singular, por `Ams0`, es decir, adjetivo, masculino, singular, sin grado, si la palabra actual es `transmisor` y la segunda palabra anterior es `el`

`P Scms nexttag P`: cambiar la etiqueta `P`, es decir, preposición, por `Scms`, es decir, sustantivo común, masculino, singular, si la palabra siguiente aparece etiquetada con la etiqueta `P`

A través de estos ejemplos, se puede apreciar que el formalismo de reglas contextuales del etiquetador de Brill constituye un sencillo pero potente mecanismo, que es capaz de resolver las concordancias de género y número dentro de una misma categoría, las ambigüedades entre distintas categorías, como por ejemplo, adjetivo/sustantivo, y hasta puede evitar que aparezcan dos preposiciones seguidas. □

4.2 Aprendizaje basado en transformaciones y dirigido por el error

El proceso de generación de las reglas, tanto las léxicas en el caso del etiquetador de palabras desconocidas, como las contextuales en el caso del etiquetador contextual, selecciona el mejor conjunto de transformaciones y determina su orden de aplicación. El algoritmo consta de los pasos que se describen a continuación. En primer lugar, se toma una porción de texto no etiquetado, se pasa a través de la fase o fases de etiquetación anteriores, se compara la salida con el texto correctamente etiquetado, y se genera una lista de errores de etiquetación con sus correspondientes contadores. Entonces, para cada error, se determina qué instancia concreta de la plantilla genérica de reglas produce la mayor reducción de errores. Se aplica la regla, se calcula el nuevo conjunto de errores producidos, y se repite el proceso hasta que la reducción de errores cae por debajo de un umbral dado.

La figura 4.2 ilustra gráficamente este procedimiento, que es el que da nombre a la técnica de entrenamiento desarrollada por Brill: aprendizaje basado en transformaciones y dirigido por el error. El usuario puede especificar los umbrales de error antes del entrenamiento, y puede también añadir manualmente nuevas reglas de transformación después del mismo.

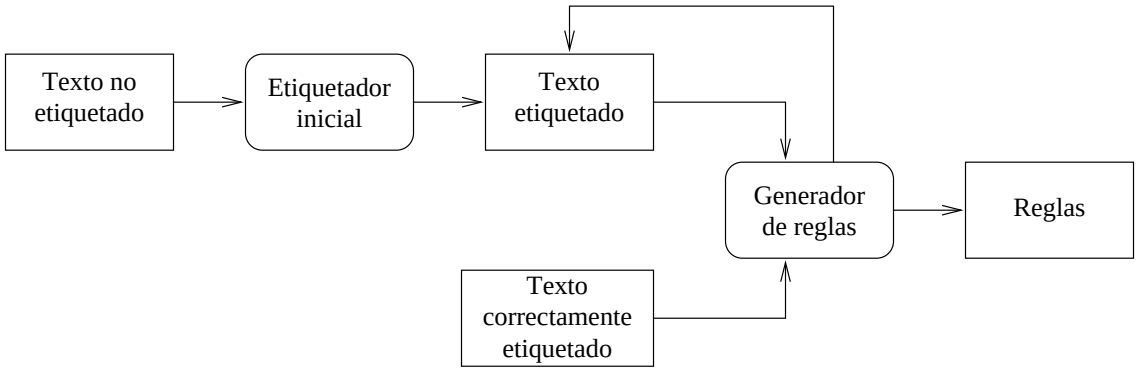

Figura 4.2: Aprendizaje basado en transformaciones y dirigido por el error

A las características anteriormente descritas podríamos añadir también una funcionalidad introducida posteriormente por el propio Brill, la cual permite obtener las k etiquetas más probables de una palabra[4] [Brill 1994], para ciertas aplicaciones en las que es posible relajar la restricción de una sola etiqueta por palabra. Brill implementa esta nueva funcionalidad mediante un sencillo cambio en el formato de las reglas:

> la acción *cambiar la etiqueta* `A` *por la etiqueta* `B` se transforma en *añadir la etiqueta* `A` *a la etiqueta* `B` o *añadir la etiqueta* `A` *a la palabra* `w`.

De esta manera, en lugar de reemplazar etiquetas, las reglas de transformación permiten ahora añadir etiquetas alternativas a una palabra. Sin embargo, el problema es que el etiquetador no nos proporciona información sobre la probabilidad de cada etiqueta. Es decir, si consideramos por ejemplo las dos mejores etiquetas para una palabra dada, la única conclusión que podemos extraer es que la que aparece en primer lugar es más probable que la que aparece en segundo lugar, pero bien podría ocurrir tanto que la primera fuera 100 veces más probable que la segunda, como que ambas fueran igualmente probables. La cuestión es que este tipo de información podría ser crucial para algunas aplicaciones, por ejemplo para la construcción de un análisis sintáctico. Los etiquetadores puramente estocásticos sí son capaces de proporcionar estas cifras y además lo hacen sin ningún esfuerzo computacional extra.

[4] *k-Best tags.*

4.3 Complejidad del etiquetador de Brill

La implementación original de Brill resulta considerablemente más lenta que las basadas en modelos probabilísticos. No sólo el proceso de entrenamiento consume muchísimo tiempo, sino que el proceso de etiquetación es también inherentemente lento. La principal razón de esta ineficiencia computacional es la potencial interacción entre las reglas, de manera que el algoritmo puede producir cálculos innecesarios.

Ejemplo 4.3 Si suponemos que `VBN` y `VBD` son las etiquetas más probables para las palabras `killed` y `shot`, respectivamente, el etiquetador léxico podría asignar las siguientes etiquetas[5]:

```
(1) Chapman/NP killed/VBN John/NP Lennon/NP
(2) John/NP Lennon/NP was/BEDZ shot/VBD by/BY Chapman/NP
(3) He/PPS witnessed/VBD Lennon/NP killed/VBN by/BY Chapman/NP
```

Dado que el etiquetador léxico no utiliza ninguna información contextual, muchas palabras pueden aparecer etiquetadas incorrectamente. Por ejemplo, en (1) la palabra `killed` aparece etiquetada incorrectamente como verbo en participio pasado, y en (2) `shot` aparece incorrectamente etiquetada como verbo en tiempo pasado.

Una vez obtenida la etiquetación inicial, el etiquetador contextual aplica en orden una secuencia de reglas e intenta remediar los errores cometidos. En un etiquetador contextual podríamos encontrar reglas como las siguientes:

```
VBN VBD prevtag NP
VBD VBN nexttag BY
```

La primera regla dice: *cambiar la etiqueta* `VBN` *por* `VBD` *si la etiqueta previa es* `NP`. La segunda regla dice: *cambiar* `VBD` *por* `VBN` *si la siguiente etiqueta es* `BY`. Una vez que aplicamos la primera regla, la palabra `killed` que aparece en las frases (1) y (3) cambia su etiqueta `VBN` por `VBD`, y obtenemos las siguientes etiquetaciones:

```
(4) Chapman/NP killed/VBD John/NP Lennon/NP
(5) John/NP Lennon/NP was/BEDZ shot/VBD by/BY Chapman/NP
(6) He/PPS witnessed/VBD Lennon/NP killed/VBD by/BY Chapman/NP
```

Una vez que aplicamos la segunda regla, la palabra `shot` de la frase (5) cambia su etiqueta `VBD` por `VBN`, generando la etiquetación (8), y la palabra `killed` de la frase (6) vuelve a cambiar su etiqueta `VBD` otra vez por `VBN`, y obtenemos la etiquetación (9):

```
(7) Chapman/NP killed/VBD John/NP Lennon/NP
(8) John/NP Lennon/NP was/BEDZ shot/VBN by/BY Chapman/NP
(9) He/PPS witnessed/VBD Lennon/NP killed/VBN by/BY Chapman/NP
```

Hemos visto que una regla `nextag` necesita mirar un *token* hacia adelante en la frase antes de poder ser aplicada, y hemos visto también que la aplicación de dos o más reglas puede producir una serie de operaciones que no se traducen en ningún cambio neto. Estos dos fenómenos constituyen la causa del no determinismo local del etiquetador de Brill. □

Este problema fue abordado por Roche y Schabes, quienes propusieron un sistema que codifica las reglas de transformación del etiquetador bajo la forma de un traductor de estado finito determinista [Roche y Schabes 1995]. El algoritmo de construcción de dicho traductor consta de cuatro pasos:

[5] La notación de las etiquetas es una adaptación del juego de etiquetas utilizado en el corpus BROWN [Francis y Kučera 1982]: `VBN` significa verbo en participio pasado, `VBD` es verbo en tiempo pasado, `NP` es sustantivo propio, `BEDZ` es la palabra `was`, `BY` es la palabra `by` y `PPS` es pronombre nominativo singular en tercera persona.

1. En primer lugar, cada transformación se convierte en un traductor de estado finito.

2. El segundo paso consiste en convertir cada traductor a su extensión local. La extensión local t_2 de un traductor t_1 se construye de tal manera que procesar una cadena de entrada a través de t_2 en un solo paso produce el mismo efecto que procesar cada posición de la cadena de entrada a través de t_1. Este paso se ocupa de casos como el siguiente. Supongamos un traductor que implementa la transformación *cambiar* `A` *por* `B` *si una de las dos etiquetas precedentes es* `C`. Este traductor contendrá un arco que transforma el símbolo de entrada `A` en el símbolo de salida `B`, de tal manera que dada la secuencia de entrada `CAA` tenemos que aplicarlo dos veces, en la segunda y en la tercera posiciones, para transformarla correctamente en `CBB`. La extensión local es capaz de realizar dicha conversión en un solo paso.

3. En el tercer paso, se genera un único traductor cuya aplicación tiene el mismo efecto que la aplicación de todos los traductores individuales en secuencia. En general, este traductor único es no determinista. Cuando necesita recordar un evento tal como `C` *apareció en la posición* i, lo hace lanzando dos caminos distintos: uno en el cual se supone que aparecerá una etiqueta que estará afectada por esa `C` precedente, y otro en el que se supone que tal etiqueta no aparecerá.

4. Este tipo de indeterminismo no es eficiente, de ahí que el cuarto paso se ocupe de transformar el traductor no determinista en uno determinista. Esto en general no es posible, ya que los traductores no deterministas pueden recordar eventos de longitud arbitraria y los deterministas no. Sin embargo, Roche y Schabes demuestran que las reglas que aparecen en los etiquetadores basados en transformaciones no generan traductores con esta propiedad. Por tanto, en la práctica siempre es posible transformar un etiquetador basado en transformaciones en un traductor de estado finito determinista.

Por tanto, el algoritmo de Brill podría necesitar RKn pasos elementales para etiquetar una cadena de entrada de n palabras, con R reglas aplicables en un contexto de hasta K *tokens*. Con el traductor de estado finito propuesto por Roche y Schabes, para etiquetar una frase de longitud n palabras, se necesitan sólo n pasos, independientemente del número de reglas y de la longitud del contexto que éstas utilizan. Esto significa que el proceso de etiquetación añade a la lectura del texto de entrada una carga computacional que es despreciable en comparación con tratamientos posteriores tales como los análisis sintáctico y semántico. Con los etiquetadores basados en traductores se pueden llegar a obtener velocidades de etiquetación de varias decenas de miles de palabras por segundo, mientras que con los etiquetadores basados en modelos de Markov esa velocidad puede ser de un orden de magnitud menos. Existen trabajos que estudian la transformación de modelos de Markov ocultos en traductores de estado finito [Kempe 1997], pero en este caso no se puede alcanzar una equivalencia completa ya que los autómatas no pueden simular de una manera exacta los cálculos de punto flotante involucrados en el algoritmo de Viterbi.

4.4 Relación con otros modelos de etiquetación

Se han esbozado ya algunas de las diferencias conceptuales más importantes que existen entre el etiquetador de Brill y los etiquetadores puramente estocásticos. Esta sección completa un poco más el estudio comparativo de los principios de funcionamiento de éstas aproximaciones y de otras relacionadas. Finalmente, se citan otros posibles campos de aplicación en los que el aprendizaje basado en transformaciones ha funcionado también con éxito.

4.4.1 Árboles de decisión

El aprendizaje basado en transformaciones presenta algunas similitudes con los árboles de decisión[6]. Un árbol de decisión [Schmid 1994, Brown *et al.* 1991] se puede ver como un mecanismo que etiqueta todas las hojas dominadas por un nodo con la etiqueta de la clase mayoritaria de ese nodo. Posteriormente, a medida que descendemos por el árbol, reetiquetamos las hojas de los nodos hijos, si es que difieren de la etiqueta del nodo padre, en función de las respuestas a las cuestiones o decisiones que aparecen en cada nodo. Esta manera de ver los árboles de decisión es la que muestra el parecido con el aprendizaje basado en transformaciones, ya que ambos paradigmas realizan series de reetiquetados trabajando con subconjuntos de datos cada vez más pequeños.

En principio, el aprendizaje basado en transformaciones es más potente que los árboles de decisión [Brill 1995a]. Es decir, existen tareas de clasificación que se pueden resolver con el aprendizaje basado en transformaciones, pero no con los árboles de decisión. Sin embargo, no está muy claro si este tipo de potencia extra se utiliza o no en aplicaciones de procesamiento de lenguaje natural.

La principal diferencia entre estos dos modelos es que los datos de entrenamiento se dividen en cada nodo de un árbol de decisión, y que se aplica una secuencia de *transformaciones* distintas para cada nodo: la secuencia correspondiente a las decisiones del camino que va desde la raíz hasta ese nodo. Con el aprendizaje basado en transformaciones, cada transformación de la lista de transformaciones *aprendidas* se aplica a todo el texto, generando una reescritura cuando el contexto de los datos encaja con el de la regla. Como resultado, si minimizamos en función de los errores de etiquetación cometidos, en lugar de considerar otro tipo de medidas indirectas más comunes en el caso de los árboles de decisión, tales como la entropía, entonces sería relativamente sencillo alcanzar el 100% de precisión en cada nodo hoja. Sin embargo, el rendimiento sobre textos nuevos sería muy pobre debido a que cada nodo hoja estaría formado por un conjunto de propiedades totalmente arbitrarias, que aunque han sido extraídas de los datos de entrenamiento no son completamente generales.

Sorpredentemente, el aprendizaje basado en transformaciones parece ser inmune a este fenómeno [Ramshaw y Marcus 1994]. Esto se puede explicar parcialmente por el hecho de que el entrenamiento siempre se realiza sobre todo el conjunto de datos. Pero el precio que hay que pagar para obtener este tipo de robustez es que el espacio de secuencias de transformaciones debe ser grande. Una implementación *naive* del aprendizaje basado en transformaciones sería por tanto ineficiente. No obstante, existen maneras inteligentes de realizar las búsquedas en ese espacio [Brill 1995b].

4.4.2 Modelos probabilísticos en general

La gran ventaja de la etiquetación basada en transformaciones es que se pueden establecer decisiones sobre un conjunto de propiedades más rico que en el caso de los modelos puramente estocásticos. Por ejemplo, se puede utilizar simultáneamente información de los contextos izquierdo y derecho, y las palabras concretas, no sólo sus etiquetas, pueden influir en la etiquetación de las palabras vecinas.

Otro punto clave es que las reglas de transformación son más fáciles de entender y de modificar que las probabilidades de transición y de generación de palabras en los etiquetadores probabilísticos. Sin embargo, está claro también que es más difícil prever el efecto que puede llegar a tener la modificación de una regla dentro de una secuencia de aplicación, ya que el comportamiento de cada regla depende de la ejecución de las reglas previas y pueden surgir numerosas y complejas interacciones entre ellas.

[6]También denominados *decision trees*.

Es importante también señalar que la etiquetación basada en transformaciones es claramente un método estadístico. Es decir, aunque no se hace un uso explícito de la teoría probabilística y aunque existe un componente basado en reglas, estas reglas se generan de una manera cuantitativa a partir de contadores calculados directamente sobre los textos. Por tanto, se trata de un método no supervisado[7] y de aplicación completamente automatizada. Desde este punto de vista, la única diferencia es que los cálculos con números se realizan sólo durante el proceso de aprendizaje, el cual además no presenta problemas de sobreentrenamiento, y una vez que el aprendizaje está hecho, el proceso de etiquetación resulta ser puramente simbólico y es por ello que se puede implementar en una estructura computacional muy eficiente.

Por último, dado que el rendimiento de los etiquetadores basados en transformaciones va a resultar muy similar al de los puramente estocásticos, la decisión final entre utilizar unos u otros dependerá casi exclusivamente de en qué tipo de sistema va a estar integrado el etiquetador y para qué tipo de aplicaciones se va a utilizar.

Además de al proceso de etiquetación, el aprendizaje basado en transformaciones se ha aplicado también al análisis sintáctico [Brill 1993a, Brill 1993c], al problema de la ligadura de la frase preposicional [Brill y Resnik 1994] y a la eliminación de ambigüedades semánticas [Dini *et al.* 1998].

[7] En el sentido de que lo que hay presente en los textos de entrenamiento son las etiquetas, pero lo que realmente se extrae de ellos son las reglas.

Parte III

Reglas contextuales y traductores de estado finito

Capítulo 5

Etiquetación utilizando reglas contextuales

Las técnicas para la etiquetación de textos vistas hasta ahora son las más usadas tradicionalmente. Llegados a este punto nos disponemos a estudiar otro método. La razón básicamente es que con los métodos estudiados hasta ahora no se puede mejorar el número de aciertos, dejando una cota en su precisión de un 96% aproximadamente. Estos resultados, además, empeoran utilizando textos de distinto tipo a los usados en el entrenamiento. Cabe destacar que la precisión es un factor muy importante, ya que el etiquetado será normalmente un paso de preprocesado, de manera que los errores aquí cometidos se arrastrarán en las fases posteriores.

Con el propósito de mejorar la precisión en el etiquetado se pasó a investigar otras técnicas de etiquetación. Una de las ideas fue la de volver a las primeras soluciones, que consistían en la utilización de reglas escritas por humanos. Este método no dio muy buenos resultados en su momento, con lo cual había que replantearlo. La idea general en la que se basa el replanteamiento consiste en la utilización de reglas de menor compromiso para evitar así errores en situaciones dudosas. De este modo se obtuvieron una serie de métodos de alta precisión, con el inconveniente de que algunas palabras quedan ambiguas después del etiquetado. Esto es así porque no se utilizan reglas de compromiso máximo. A pesar de esto, la mayoría de las palabras tienen una única etiqueta después de pasar por el proceso de etiquetación.

Este método presenta las siguientes ventajas:

- Un grado de aciertos muy alto en la etiquetación del texto. El resultado obtenido es superior al conseguido por cualquier otro método. Los creadores del sistema EngCG afirman llegar a un 99% de precisión e incluso superarlo en ocasiones [Voutilainen 1995]. Los creadores del sistema Rtag afirman rondar el 98% [Sánchez *et al.* 1999].

- La precisión, en principio, no depende del tipo de texto, ya que no hay un corpus de entrenamiento como con los otros métodos. Al enfrentarse a texto totalmente nuevo (en cuanto a temática, estilo, etc.) es sin duda la técnica que obtiene mejores resultados con diferencia.

- Es posible hacer reglas a mayores para un tipo de texto dado, de esta manera se puede aprovechar al máximo la información disponible.

- Se puede acudir a reglas heurísticas que, normalmente, mejoran la precisión del etiquetador.

- El conocimiento del etiquetador se puede revisar y mejorar fácilmente, ya que se esta tratando con reglas escritas por humanos. Esto, en la práctica, no es posible en el etiquetador de Brill ya que sus reglas interactúan con otras, y modificarlas a mano es arriesgado porque puede provocar anomalías en el funcionamiento de dicho etiquetador.
- Al utilizar reglas obtenemos un nivel de expresividad alto, de esta manera a la hora de etiquetar una palabra podemos tener en cuenta factores que un etiquetador estadístico no puede utilizar.
- Estas técnicas se adecuan muy bien para lenguajes con un tipo de ambigüedades distintas a las del inglés o el español. Oflazer y Tür afirman que este tipo de técnicas son las más adecuadas para lenguajes como el turco y el finlandés [Oflazer y Tür 1996].

En cuanto a las desventajas podemos citar las siguientes:

- Aumentan los costes de tiempo ya que las reglas deben ser diseñadas por expertos humanos. Para evitar esto se están empezando a utilizar reglas inducidas automáticamente como ayuda a los expertos [Oflazer y Tür 1996, Samuelsson *et al.* 1996, Màrquez y Padró 1997, Màrquez y Rodríguez 1997], pero no de manera exclusiva, ya que así romperíamos la filosofía de aprovechar el conocimiento humano, y además obtendríamos un etiquetdor similar al de Brill, pero de menos precisión.
- Como no se llega a un máximo nivel de compromiso, al final del etiquetado quedan ambigüedades, lo que significa que estos métodos no se pueden usar por si solos cuando se necesita una única etiqueta por palabra.
- Estos métodos son los más novedosos, con lo cual los menos estudiados, lo que supone: una falta de estándares, heterogeneidad, etc.

Nos podemos encontrar varias aproximaciones posibles a la hora de buscar un formalismo adecuado que refleje esta idea. Una primera aproximación puede ser la de seleccionar y eliminar etiquetas según se cumplan o no una serie de restricciones. El sistema EngCG [Voutilainen 1995] se basa en esta idea, y también es utilizada en muchos otros etiquetadores [Oflazer y Tür 1996]. Una segunda aproximación es la de usar reglas que den puntuaciones positivas o negativas a las distintas etiquetas de una palabra, eliminando, *a posteriori*, aquellas que finalmente bajen de un umbral determinado. El sistema Rtag de la Real Academia Española de la Lengua [Porta 1996, Sánchez *et al.* 1999] utiliza esta idea. También nos podemos encontrar con aproximaciones que resultan de la combinación de las dos anteriores o incluso otras ideas.

Se considera más adecuada la primera aproximación, y esto se debe principalmente a:

- Se adapta mejor al paradigma de etiquetación, sobre todo a la idea de menor compromiso. Consiste en la eliminación de todas aquellas etiquetas que se consideran incorrectas, sin intervenir en las dudosas. Con la otra aproximación las etiquetas no consideradas se eliminan totalmente.
- Es más predecible, de manera que hará mejor su trabajo aunque refinará un menor número de etiquetas. De esta manera el número de errores producidos será menor, factor importante teniendo en cuenta que el etiquetador de reglas formará parte de un sistema mayor. La segunda aproximación sería más adecuada en sistemas independientes, ya que se puede llegar a una etiqueta por palabra, pero perdería precisión.
- Evita tener que asignar un umbral de corte y definir los pesos que se sumarán o restarán al valor de cada etiqueta.

5.1 Definición del lenguaje de reglas

Ha llegado el momento de definir el lenguaje de reglas que los lingüistas deben manejar para realizar el etiquetado. Entre las caracteristicas que buscamos para este lenguaje se pueden citar las siguientes:

- Potencia y expresividad, para que así los lingüistas puedan considerar el mayor número de casos posibles.
- Sintaxis sencilla, para facilitar su implementación y uso.
- Cumplimiento de los estándares en caso de existir, para facilitar su implantación.

La heterogeneidad de los lenguajes de reglas existentes es uno de los grandes problemas actuales. No sólo no hay un estándar, sino que los lenguajes son muy distintos unos de otros.

Se puede decir que básicamente lo que se usa son reglas del tipo: si se cumple una condición (como, por ejemplo, que la palabra posterior a la actual sea un verbo) se ejecuta una acción (como, por ejemplo, seleccionar la etiqueta sustantivo de la palabra actual). En las condiciones de las reglas es donde nos vamos a encontrar con mucha variedad, tanto en los tipos de condición como en la sintaxis utilizada. Sin embargo, en lo que a las acciones se refiere no hay mucha variedad, sino que suelen ser: seleccionar una etiqueta posible o borrar una etiqueta de las posibles.

Existen lenguajes sencillos pero poco potentes, como el definido por el departamento de *Computer Engineering and Information Science* de la Univerdidad de Bilkent de Turka [Oflazer y Tür 1996]. El problema de este lenguaje es la poca expresividad.

El lenguaje utilizado en el sistema EngCG [Voutilainen 1995], es lo que más se parece a un estándar. Sus creadores son los que más han avanzado en este campo y han definido un lenguaje que bautizaron como *Constraint Grammars*. Sin embargo este formalismo presenta algunos problemas importantes, entre las cuales destacan los siguientes:

- Este lenguaje pretende abordar más problemas que el del etiquetado morfológico. De hecho une el etiquetado y el análisis sintáctico, cuando tradicionalmente estos dos problemas se tratan en módulos distintos por la gran complejidad que presentan ya por separado. Este proyecto va a abordar una de las partes, la del etiquetado, y las razones de ello se citan a continuación:
  - Las herramientas de PLN que han sido implementadas por el grupo COLE (COmpiladores y LEnguajes) del Departamento de Computación de la Universidad de A Coruña trabajan con módulos independientes, con lo cual hacer un módulo conjunto rompería las planificaciones del equipo de trabajo y con mucha seguridad acarrearía problemas de integración.
  - Nos podemos encontrar con problemas en los que sólo nos va a interesar trabajar con un etiquetador y no con un analizador sintáctico, como puede ser la lematización.
  - El hecho de abarcar más de un simple etiquetador de palabras hace que potencialmente se ralentice su ejecución, influyendo de forma negativa en los casos en los que sólo se necesite etiquetar.
  - El análisis sintáctico ha obtenido sus mejores resultados resolviendo los dos problemas por separado.
  - Un punto importante a la hora de desarrollar un sistema, independientemente del tamaño del mismo, es la modularidad, donde se busca mínimo acoplamiento y máxima cohesión.

- Sin embargo, el mayor problema reside en la complejidad del lenguaje ya que la comprensión del mismo no es fácil. Principalmente se debe a que:
  - Se abusa excesivamente de símbolos nemotécnicos.
  - Se admite un abanico de condiciones muy amplio. Esto desemboca en una gran expresividad pero complica la sintaxis, dificultando así su utilización.
  - El abarcar más que la etiquetación contribuye a la complejidad del formalismo.

Claramente las *Constraint Grammars* son muy potentes. Sin embargo, el añadir potencia implica una disminución de la velocidad del etiquetador, y aumenta la complejidad de manejo e implementación. Puede ser que el añadir una regla más aumente el tiempo de ejecución de todas las reglas del etiquetador y, en la práctica, esta nueva regla sólo sirva para añadir un par de casos más que van a resolver unas pocas ambigüedades en un texto grande.

Por todo lo comentado hasta aquí, quizá sea mejor definir un nuevo lenguaje para el formalismo de reglas, donde se mantenga un compromiso entre potencia, sencillez, eficacia y velocidad de ejecución. Este nuevo formalismo es el definido por [Reboredo y Graña 2000], que se basa en las *Constraint Grammars*, pero que difiere en los siguientes puntos:

- Sintaxis más intuitiva y legible.
- Elimina el manejo de términos sintácticos.
- Simplifica las condiciones (incluye todos los tipos de condición definidos en las *Constraint Grammars*).
- Permite comparar etiquetas con palabras no ambiguas y ambiguas.

5.1.1 LEMMERS: Lenguaje de Etiquetado MEdiante Restricciones Simples.

Este es el lenguaje para el formalismo de reglas definido por [Reboredo y Graña 2000]. Tras haber estudiado y habernos familiarizado con este lenguaje nos dimos cuenta de que la notación utilizada para definir estas reglas no es muy clara y puede conducir a error. Veámoslo a continuación.

Las reglas siguen la clasificación hecha por Samuelsson, Tapanainen y Voutilainen en [Samuelsson *et al.* 1996]. De esta manera nos encontramos con:

1. Reglas locales, que son de la forma:

   Acción (*Categoría de ejecución*) ([**NOT**] *Entero* [**ALGUNO**] *ListaValores*, ...);

   siendo:

   - *Acción*: acción a ejecutar si se cumplen las condiciones de la regla.
     Hay tres acciones posibles:
     - **BORRA**: elimina una o varias etiquetas dentro de las posibles de la palabra, según qué etiqueta se indique en el apartado de *Categoría de ejecución*. La regla no se ejecuta si dicha etiqueta no existe o es la única para la palabra.
     - **SELECCIONA**: selecciona una o varias etiquetas dentro de las posibles de la palabra.
     - **FUERZA**: fuerza a que la palabra tenga la etiqueta dada aunque dicha etiqueta no exista entre el conjunto de etiquetas posibles.

- *Categoría de ejecución*: etiqueta sobre la que se ejecuta la acción.
- *Entero*: entero que indica la posición de la palabra, respecto de la palabra actual, con la que queremos comparar los valores en una condición.
- *ListaValores*: es una lista de valores (para más información consultar la sección 5.1.1 de [Reboredo y Graña 2000]). Una condición se cumplirá si se cumple la comparación de los valores de la palabra indicada por *Entero* con todos los valores indicados en *ListaValores*. Si alguno de estos valores fuera un conjunto, para ese valor sólo se mirará que pertenezca al conjunto.

El primer problema con el que nos encontramos es el significado de la coma y los puntos suspensivos que van a continuación de la *ListaValores*. No queda claro si representan un y-lógico ó un o-lógico. Lo único que sabemos es que los puntos suspensivos indican que se puede repetir lo definido más de una vez.

Siguiendo con las reglas, vemos claramente que existen cuatro tipo de comparaciones, debido a las opciones NOT y ALGUNO. Vamos a verlas a continuación y analizaremos si presentan algún problema:

(a) `Entero ListaValores`: se comparan todos los valores de la lista con todos los valores de la palabra indicada por entero. Devolverá verdadero si la palabra es no ambigua y los valores encajan o, si la palabra es ambigua y las comparaciones son sólo con literales[1].
Veamos algunos ejemplos[2]:

Caso a)

El	sobre
D	S
P	P
	V

```
BORRA (D) (1 { S } );
```
Esta regla no se ejecutaría porque `sobre` *es una palabra ambigua y la comparación la estamos haciendo con etiquetas.*

```
BORRA (D) (1 @sobre);
```
Esta regla si se ejecutaría ya que `sobre` *es una palabra ambigua y la comparación la estamos haciendo con un literal.*

Caso b)

El	niño
D	S
P	

```
BORRA (P) (1 { S } );
```
Esta regla si se ejecutaría porque `niño` *no es una palabra ambigua y los valores encajan.*

[1] Valor que se utiliza para hacer referencia a una palabra que aparece en el texto. Se escribe la palabra tal cual precedida de @. Existen dos literales especiales, @<@ y @>@, que son principio de oración y final de oración respectivamente.

[2] Para este y futuros ejemplos suponemos que tenemos un *tag set* reducido formado por las siguientes etiquetas:
D → Determinante. Pron → Pronombre. V → Verbo.
P → Preposición. S → Sustantivo.

(b) `NOT Entero ListaValores`: es la negación de la anterior. Devolverá verdadero si la palabra referida es ambigua, salvo que lo que estemos comparando sea el literal.

Problema: No queda claro lo que quiere decir esta condición. Si la palabra es ambigua y las condiciones no se cumplen, no se sabe bien qué es lo que devuelve. Podría ser verdadero porque se trata de la negación de la anterior, pero también podría ser falso. Sin embargo nos dice que se devuelve verdadero si la palabra es ambigua.
Veámoslo con un ejemplo:

El	sobre
D	S
P	P

```
BORRA (P) (NOT 1 V);
```
Esta regla podría devolver:
Verdadero, porque la palabra `sobre` *es ambigua independientemente de que se cumpla o no la condición.*
Verdadero, porque la palabra `sobre`, *independientemente de ser ambigua, no tiene* `V` como etiqueta.
Falso, porque a pesar de que la palabra `sobre` *sea ambigua, la etiqueta* `V` *no es una de las candidatas.*

Resumiendo, no queda claro a qué afecta el NOT ni cómo se tratan las ambigüedades.

(c) `Entero ALGUNO ListaValores`: como el primero, salvo que si la palabra es ambigua, se comprueba si los valores con los que se compara están en alguna de las opciones.
Veamos un ejemplo donde:

El	sobre
D	S
P	P
	V

```
BORRA (P) (1 ALGUNO S);
```
Esta regla si se ejecutaría ya que la palabra `sobre` *es ambigua .*

Pero si la palabra en cuestión no fuese ambigua no queda claro qué ocurriría.

(d) `NOT Entero ALGUNO ListaValores`: es la negación exacta de la anterior. Los valores indicados no deben existir en ninguna de las opciones.

2. Reglas barrera, son de la forma:

$$\textit{Acción}\ (\textit{Categoría de ejecución})\ (\ \textit{Dirección}\ [\textbf{ALGUNO}]\ \textit{ListaValores}_1 \\ <\ \textbf{BARRERA}\ >\ [\textbf{ALGUNO}]\ \textit{ListaValores}_2,\ldots);$$

siendo:

- *Acción*, *Categoría de ejecución* y *ListaValores* lo mismo que en el apartado anterior.
- *Dirección*: símbolo que indicará la dirección en que funcionará la regla.

Podemos apreciar a simple vista que este tipo de reglas van a presentar los mismos problemas que hay en las reglas locales.

3. Reglas especiales[3]. Se usan principalmente en casos heurísticos. Ejecutan siempre una acción.
   Son de la forma:

   Acción **SIEMPRE** (*Categoría de ejecución*);

   con la restricción de que la acción no podrá ser un `FUERZA`, ya que dejaría todo el texto con la misma etiqueta.

   Este tipo de regla habla por sí misma, con lo cual es lo suficientemente clara.

Como conclusión, después de haber analizado con cuidado todos estos puntos, decidimos mejorar la sintaxis del tipo de reglas que presentan problemas con el propósito de hacerlas más sencillas, más expresivas y más fáciles de entender.

5.2 Mejoras del formalismo de reglas del lenguaje LEMMERS

Las mejoras que hemos considerado sobre el formalismo de reglas del lenguaje LEMMERS sigue respetando la clasificación de Samuelsson, Tapanainen y Voutilainen indicada en [Samuelsson *et al.* 1996]:

1. Reglas locales:
   La alternativa que proponemos básicamente va a influir sobre este tipo de reglas, que como veremos a continuación resultarán más legibles y sencillas.
   Su forma será:

   Acción (*CategoríaEjecución*) ([**NOT**] *Entero Condición ConjuntoEtiquetas*, ...);

   siendo:

   - *Acción*: acción a ejecutar si se cumplen las condiciones de la regla. Hay tres acciones posibles, que se corresponden con las indicadas en el apartado anterior.
   - *CategoríaEjecución*: categoría o etiqueta sobre la que se ejecuta la acción. En el caso de ser una categoría, se extiende la regla en n reglas diferentes, siendo n el número de etiquetas que se pueden formar a partir de dicha categoría. Por ejemplo si nos hablan de *sustantivo* y tenemos un conjunto extenso de etiquetas para sustantivo, se generarían tantas reglas como etiquetas diferentes existen para sustantivo. Es decir, para:

sustantivo	Scms
	Scmp
	Scfs
	Scfp

     generaríamos cuatro reglas diferentes, cada una con una etiqueta.
   - *Entero*: entero que indica la posición de la palabra, respecto de la palabra actual, con la que queremos comparar los valores en una condición.

[3] También se podrían denominar *reglas raras* debido a lo poco frecuente de su uso.

- *Condición*: operación de conjuntos sobre la que se determina la veracidad de la regla. Esta operación puede ser:
  - **ES**: simula la igualdad de conjuntos. Es decir, la condición de la regla será verdadera si el conjunto de etiquetas indicado por *Entero* es igual a *ConjuntoEtiquetas*. En caso contrario, la condición de la regla será falsa y por consiguiente ésta no ejecutará su acción.
    Si la palabra indicada por *Entero* tiene una sola etiqueta, entonces las acciones `BORRA` y `SELECCIONA` nunca se ejecutarán, independientemente del valor de la condición. Tampoco se ejecutarán si dicha etiqueta no existe.
  - **CONTIENE**: simula la operación de inclusión de conjuntos. Es decir, la condición de la regla será verdadera si el conjunto de etiquetas indicado por *Entero* incluye a *ConjuntoEtiquetas*, o lo que es lo mismo si *ConjuntoEtiquetas* está incluido en el conjunto indicado por *Entero*. Cabe destacar que hablamos de inclusión estricta, con lo cual no se permite la igualdad. Si se quiere representar un caso en el que se dé la condición de $\supseteq$ se deben escribir dos reglas:
    Acción (etiqueta) (Entero `ES` *ConjuntoEtiquetas);*
    Acción (etiqueta) (Entero `CONTIENE` *ConjuntoEtiquetas);*
  - **PERTENECE**: antes de nada indicar que esta operación únicamente se utilizará cuando queramos que intervengan palabras en la condición de la regla. Simula la operación de pertenencia de conjuntos. Es decir, la condición será verdadera si la palabra indicada por *Entero* es un elemento de *ConjuntoEtiquetas*.
- *ConjuntoEtiquetas*: recalcar que se trata de un *conjunto* de elementos, donde los elementos pueden ser categorías o etiquetas. En el caso de las categorías lo que se hace es expandir dicha categoría en sus etiquetas correspondientes. De manera que el conjunto estará formado por todas las etiquetas que se pueden obtener a partir de dicha categoría, además de lo que ya había si fuera el caso. Por ejemplo, para:

sustantivo
Scms
Scmp
Scfs
Scfp

obtendríamos un conjunto donde por lo menos aparecerían estas cuatro etiquetas.

Ejemplo 5.1 A continuación se muestran algunos casos donde las condiciones de las reglas son verdaderas:

(a)

El	toca	el	bajo	
D	V	D	S	$\Longrightarrow$ `BORRA (D) (3 ES { S } );`
⋮	⋮	⋮		

(b)

El	toca	el	bajo	
D	V	D	S	$\Longrightarrow$ `BORRA (D) (3 ES { S, P } );`
⋮	⋮	⋮	P	

(c)

El	toca	el	bajo	
D	V	D	S	$\Longrightarrow$ `BORRA (D) (3 CONTIENE { S } );`
⋮	⋮	⋮	⋮	

(d)

El	toca	el	bajo
D	V	D	S
⋮	⋮	⋮	P
⋮	⋮	⋮	⋮

$\Longrightarrow$ `BORRA (D) (3 CONTIENE { S, P } );`

□

Es importante mencionar que se van a permitir construir reglas con condiciones múltiples simulando un y-lógico. Su forma es:

Acción (*CategoríaEjecución* ([**NOT**] *Entero Condición*$_1$ *ConjuntoEtiquetas*,
[**NOT**] *Entero Condición*$_2$ *ConjuntoEtiquetas*,
...,
[**NOT**] *Entero Condición*$_n$ *ConjuntoEtiquetas*);

Para simular un o-lógico se escriben tantas reglas con condiciones simples como operandos lógicos queremos que participen en la operación. Tiene la siguiente forma:

Acción (*CategoríaEjecución* ([**NOT**] *Entero Condición*$_1$ *ConjuntoEtiquetas*);
Acción (*CategoríaEjecución*) ([**NOT**] *Entero Condición*$_2$ *ConjuntoEtiquetas*);
...;
Acción (*CategoríaEjecución*) ([**NOT**] *Entero Condición*$_n$ *ConjuntoEtiquetas*);

2. Reglas barrera, que son de la forma:

Acción (*Categoría de ejecución*) (*Dirección Condición ConjuntoEtiquetas*$_1$ **BARRERA**
Condición ConjuntoEtiquetas$_2$,
...);

siendo:

- *Acción, CategoríaEjecución, Condición, ConjuntoEtiquetas* lo mismo que lo indicado en el apartado anterior.
- *Dirección*: símbolo que indicará la dirección en la que funcionará la regla:

  $+*$ que indica hacia la derecha o adelante.
  $-*$ que indica hacia la izquierda o atrás.

Ejemplo 5.2 Un ejemplo de este tipo de regla podría ser el siguiente:

```
BORRA (S) (-* CONTIENE {V} BARRERA ES {D});
```

que significa, si antes de una palabra hay un *verbo* y entre ese verbo y es palabra no hay ninguna palabra que sea un *determinante*, esa palabra no podrá ser un *sustantivo*. □

3. Reglas especiales, exactamente iguales a las vistas en el punto anterior.

5.2.1 Esquemas de reglas

A continuación se muestran los esquemas generales de reglas que nos podemos encontrar. Después será labor de los lingüistas particularizarlas para, a continuación, aplicarlas correctamente.

1. Reglas Locales, que como vimos son:

   Acción (*CategoríaEjecución*) ([**NOT**] *Entero Condición ConjuntoEtiquetas*, ...);

   y su esquema general obedece a la siguiente estructura:

   - Si sólo intervienen etiquetas:

     {BORRA | SELECCIONA | FUERZA} (CategoríaEjecución)
     ({0 | $n > 0$ | $n < 0$} {ES | CONTIENE} (ConjuntoEtiquetas), ...);

     {BORRA | SELECCIONA | FUERZA} (CategoríaEjecución)
     (NOT {0 | $n > 0$ | $n < 0$} {ES | CONTIENE} (ConjuntoEtiquetas), ...);

   - Si intervienen palabras:

     {BORRA | SELECCIONA | FUERZA} (CategoríaEjecución)
     ({0 | $n > 0$ | $n < 0$} PERTENECE (ConjuntoPalabras), ...);

     {BORRA | SELECCIONA | FUERZA} (CategoríaEjecución)
     (NOT {0 | $n > 0$ | $n < 0$} PERTENECE (ConjuntoPalabras), ...);

Ejemplo 5.3 Veamos algunos ejemplos de reglas que se podrían aplicar al siguiente enrejado. También se va a reflejar la evolución del enrejado a medida que las reglas se van ejecutando.

Las reglas son:

(a) `BORRA (S) (-1 PERTENECE {Juan});`
La palabra actual no puede ser un *sustantivo* si la anterior es *Juan*.

(b) `SELECCIONA (D) (-1 ES {V}, 1 CONTIENE {S});`
Si la palabra anterior es un *verbo* y la siguiente puede ser un *sustantivo*, entonces la palara actual será una *preposición*.

(c) `SELECCIONA (S) (NOT -1 ES {P}, 0 PERTENECE {vino});`
La palabra actual será un *sustantivo* si es la palabra *vino* y la palabra anterior no es una *preposición*.

Y el enrejado va evolucionando de la siguiente forma:

Enrejado inicial.	Juan	vino	a	probar	este	vino
	S	S	P	V	D	S
		V			Pron	V
					S	
Primera regla encajada y ejecutada.	Juan	vino	a	probar	este	vino
	S	V	P	V	D	S
					Pron	V
					S	
Segunda regla encajada y ejecutada.	Juan	vino	a	probar	este	vino
	S	V	P	V	D	S
						V
Tercera regla encajada y ejecutada.	Juan	vino	a	probar	este	vino
	S	V	P	V	D	S

□

Ejemplo 5.4 Veamos un ejemplo en el que se refleje la utilidad de las reglas que llevan un FUERZA.

El	fue	a	cenar
D	V	P	V

- `FUERZA (Pron) (0 ES {D}, NOT 1 ES {S});`
  Si la palabra actual puede ser un *determinante* o un *artículo*, y la siguiente palabra no es un *sustantivo*, entonces la palabra actual debe ser forzosamente un *pronombre*.

El	fue	a	cenar
Pron	V	P	V

□

2. Reglas barrera, que son:

Acción (*Categoría de ejecución*) (*Dirección Condición ConjuntoEtiquetas*$_1$ **BARRERA** *Condición ConjuntoEtiquetas*$_2$, ...);

obedecen al siguiente esquema general:

- Si participan etiquetas en las reglas:
  {`BORRA` | `SELECCIONA` | `FUERZA`} `(CategoríaEjecución)`
  {+∗,−∗} {`ES` | `CONTIENE`} `(ConjuntoEtiquetas)` < `BARRERA` >
  {`ES` | `CONTIENE`} `(ConjuntoEtiquetas), ...);`

- Si participan palabras y etiquetas de forma combinada:
  {BORRA | SELECCIONA | FUERZA} (CategoríaEjecución)
  {+∗,−∗} PERTENECE (ConjuntoPalabras) < BARRERA >
  {ES | CONTIENE} (ConjuntoEtiquetas), ...);

  {BORRA | SELECCIONA | FUERZA} (CategoríaEjecución)
  {+∗,−∗} {ES | CONTIENE} (ConjuntoPalabras) < BARRERA >
  PERTENECE (ConjuntoPalabras), ...);

- Si participan únicamente palabras:
  {BORRA | SELECCIONA | FUERZA} (CategoríaEjecución)
  {+∗,−∗} PERTENECE (ConjuntoPalabras) < BARRERA >
  PERTENECE (ConjuntoPalabras), ...);

Ejemplo 5.5 Veamos a continuación algunos ejemplos:

Juan	vino	a	probar	el	vino
S	S	P	V	A	S
	V			D	V
				P	

- BORRA (V) (−∗ ES {V} < BARRERA > CONTIENE {S});
  Si antes de una palabra hay un *verbo* y, entre ese verbo y esa palabra no hay ninguna palabra que pueda funcionar como *sustantivo*, esa palabra no será un verbo.

Juan	vino	a	probar	el	vino
S	S	P	V	A	S
	V			D	
				P	

□

3. Reglas especiales, que como vimos son de la forma:

   Acción **SIEMPRE** (*Categoría de ejcución*);

   y cuyo esquema de reglas es:

   {BORRA | SELECCIONA} SIEMPRE (CategoríaEjecución);

   Ejemplo 5.6 Un ejemplo de este tipo de reglas podría ser:
   Supongamos que tenemos un diccionario donde aquellas palabras que no son del castellano las etiquetamos como palabraExtranjera. Suponiendo que sabemos *a priori* que el texto está escrito en castellano, podríamos incluir una regla que eliminase estas palabras. Y esta regla sería:

   BORRRA SIEMPRE (palabraExtranjera);

□

Capítulo 6

Compilación de reglas contextuales utilizando traductores de estado finito

La ejecución tradicional de las reglas contextuales consiste en aplicar cada una de ellas sobre la cadena de entrada, llevando a cabo, en cada caso posible, los cambios oportunos. Es decir, consiste en un proceso iterativo en el que las reglas se van aplicando a la cadena entrada de forma secuencial. Tras la aplicación de la primera regla sobre la cadena de entrada obtendremos como salida esa misma cadena, o bien sin ningún cambio, o bien con los cambios oportunos que indique dicha regla. A continuación se aplica la siguiente regla, y así sucesivamente hasta que todas hayan sido aplicadas. De esta manera vamos alimentando a cada regla con la salida de la regla anterior. Este modelo de ejecución es muy sencillo, sin embargo presenta algunos inconvenientes, entre los cuales destacan los siguientes:

- La complejidad temporal de este proceso iterativo es elevada, ya que resulta ser proporcional al número de reglas contextuales y a la longitud de la cadena de entrada.

- Surge la necesidad de guardar salidas temporales para poder aplicar las siguientes reglas.

Como solución a este problema proponemos una compilación previa de las reglas. Este proceso de compilación transformará el conjunto de reglas en una estructura matemática denominada *traductor de estado finito*, que es la que permitirá una ejecución más eficiente. Las ventajas que obtenemos llevando a cabo la compilación de las reglas de esta manera son las que se citan a continuación:

- No se lleva a cabo ningún proceso iterativo, sino que de una sola pasada realizamos todos los cambios pertinentes sobre la entrada. Es decir, la complejidad temporal no depende ahora del número de reglas contextuales, sino que resulta ser lineal respecto sólo a la longitud de la cadena de entrada.

- No hay salidas intermedias ya que los cambios sobre la entrada se producen a medida que se avanza por el traductor.

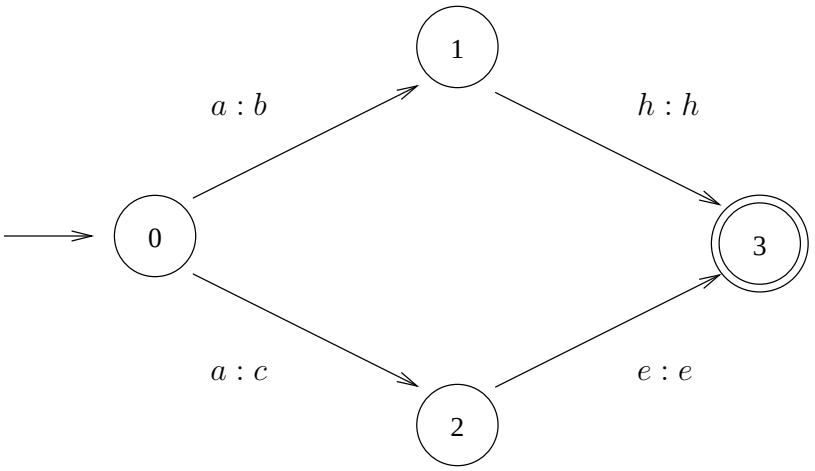

Figura 6.1: T: Ejemplo de traductor de estado finito

6.1 Definición formal de un traductor de estado finito

Un *Traductor de Estado Finito* o *FST*[1] se puede ver como un*Autómata de Estado Finito* o *FSA*[2] donde los arcos del grafo van a estar etiquetados con un par de símbolos, el símbolo de entrada y su correspondiente símbolo de salida, en lugar de con un único símbolo de entrada [Roche y Schabes 1997].

Definición 6.1 Un *Traductor de Estado Finito* o *FST* es una 6-túpla $T = (\Sigma_1, \Sigma_2, Q, i, F, E)$ donde:

- Σ_1 es un alfabeto finito, denominado *alfabeto de entrada*.
- Σ_2 es un alfabeto finito, denominado *alfabeto de salida*.
- Q es un conjunto finito de estados.
- $i \in Q$ es el estado inicial.
- $F \subseteq Q$ es el conjunto de estados finales.
- $E \subseteq Q \times \Sigma_1^* \times \Sigma_2^* \times Q$ es el conjunto de transiciones y transformaciones.

□

Ejemplo 6.1 La representación gráfica del traductor que se indica a continuación es el que se muestra en la figura 6.1:

$$T = (\{a, b, c, h, e\}, \{a, b, c, h, e\}, \{0, 1, 2, 3\}, 0, \{3\}, \{(0, a, b, 1), (0, a, c, 2), (1, h, h, 3), (2, e, e, 3)\})$$

□

A continuación proporcionamos algunas definiciones básicas sobre los *FST*,s:

Definición 6.2 Dado un *FST* $T = (\Sigma_1, \Sigma_2, Q, i, F, E)$, un *camino* de T es una secuencia $((p_i, a_i, b_i, q_i))_{i=1,n}$ de transiciones E tal que $q_i = p_{i+1}$ desde $i = 1$ hasta $n - 1$. □

[1] *Finite State Transducer*.
[2] *Finite State Automaton*.

Definición 6.3 Dado un *FST* $T = (\Sigma_1, \Sigma_2, Q, i, F, E)$ un *camino con éxito* $((p_i, a_i, b_i, q_i))_{i=1,n}$ de T es un camino de T tal que $p_1 = i$ y $q_n \in F$. Es decir, aquel que empieza en el estado inicial y termina en un estado final. □

Definición 6.4 La *primera proyección* y la *segunda proyección* de un *FST* $T = (\Sigma_1, \Sigma_2, Q, i, F, E)$ son dos autómatas de estado finito $p_1(T)$ y $p_2(T)$ tales que:

$$p_1(T) = (\Sigma_1, Q, i, F, E_{p_1}) \text{ donde } E_{p_1} = \{(q, a, q') \mid (q, a, b, q') \in E\}$$
$$p_2(T) = (\Sigma_2, Q, i, F, E_{p_2}) \text{ donde } E_{p_2} = \{(q, b, q') \mid (q, a, b, q') \in E\}$$

□

Como en el caso de los *FSAs*, los *FSTs* son muy potentes por sus propiedades algorítmicas y de cierre.

- *Cierre bajo la Union.* Si T_1 y T_2 son dos *FSTs*, entonces existe un *FST* $(T_1 \cup T_2)$ donde $\forall u \in \Sigma^*, (T_1 \cup T_2)(u) = T_1(u) \cup T_2(u)$

- *Cierre bajo la Inversión.* Si $T = (\Sigma_1, \Sigma_2, Q, i, F, E)$ es un *FST*, existe un *FST* T^{-1} tal que $T^{-1}(u) = \{v \in \Sigma^* \mid u \in T(v)\}$. Además, $T^{-1} = (\Sigma_2, \Sigma_1, Q, i, F, E^{-1})$ tal que:

  $$(q_1, a, b, q_2) \in E^{-1} \Leftrightarrow (q_1, b, a, q_2) \in E$$

- *Cierre bajo la Composición.* Dados dos *FSTs* $T_1 = (\Sigma_1, \Sigma_2, Q_1, i_1, F_1, E_1)$ y $T_2 = (\Sigma_2, \Sigma_3, Q_2, i_2, F_2, E_2)$, entonces existe un traductor $(T_1 \circ T_2)$ tal que $\forall u \in \Sigma_1^*, (T_1 \circ T_2)(u) = T_2(T_1(u))$, dando lugar al traductor $T_3 = (\Sigma_1, \Sigma_3, Q_1 \times Q_2, (i_1, i_2), F_1 \times F_2, E_3)$ tal que:

  $E_3 = \{((x_1, x_2), a, b, (y_1, y_2)) \mid \exists c \in \Sigma_2 \cup \{\epsilon\}$ tal que $(x_1, a, c, y_1) \in E_1$ y $(x_2, c, b, y_2) \in E_2\}$

  y de manera que:

  $$T_3(u) = (T_1 \circ T_2)(u) = T_2(T_1(u)), \forall u \in \Sigma_1^*$$

Definición 6.5 Un traductor de estado finito $T = (\Sigma_1, \Sigma_2, Q, i, F, E)$ es un *traductor sin ϵ-transiciones* si:

$$E \subseteq Q \times \Sigma_1 \times \Sigma_2 \times Q$$

□

6.2 Construcción de un traductor a partir de reglas contextuales

A partir de los esquemas de reglas introducidos en el capítulo anterior, es labor de los lingüistas proporcionar las reglas contextuales. Una vez que tengamos disponibles las reglas contextuales, estaremos en condiciones de construir el traductor de estado finito asociado a cada una de ellas. No obstante, antes de profundizar en la construcción de los *FST*,s, resulta interesante ver la forma de trabajo de nuestro sistema, así como los formatos internos con los que va a operar el traductor. Esto permitirá comprender con mayor claridad la forma en la que se construyen los traductores y los detalles que se deben tener en cuenta para su correcto funcionamiento.

6.2.1 Formatos de E/S con los que trabaja el traductor de estado finito

Cuando tenemos las reglas contextuales podemos empezar a construir nuestro sistema. Lo primero que vamos a ver es el formato con el que se construyen y operan los *FST*,s. Para que los procesos de construcción y ejecución de los traductores sean más eficientes, y para que los propios traductores en sí mismos sean más compactos, éstos trabajarán internamente con números enteros como sistema de representación de las palabras y de las etiquetas, en lugar de trabajar con los caracteres que conforman dichas palabras y etiquetas. De esta manera, partiendo de las reglas, hacemos lo siguiente:

- Los enteros 0, 1 y -1 están reservados. El 0 representa la cadena vacía o *epsilon*, mientras que el -1 y el 1 representan los puntos de comienzo y final de la frase a etiquetar, respectivamente.
- Con todas las palabras que aparecen involucradas en las reglas contextuales creamos un *mini-diccionario*, numerando cada una de ellas con un número negativo entre el -3 y el $-m$, siendo $m-2$ el número de palabras diferentes que aparecen en dicho conjunto de reglas. Se reserva el -2 como comodín, para aquellas palabras que aparezcan en las frases a etiquetar, y no en las reglas.
- Comprobamos que todas las etiquetas a las que se hace referencia en las reglas contextuales existen en el *tag set* de nuestro sistema. Construimos entonces un *mini-tag-set* con dichas etiquetas, a las que asignamos un número positivo comprendido entre el 3 y el n, siendo $n-2$ el número total de etiquetas diferentes que aparecen en las reglas. Los números se asignan a las etiquetas según el orden en el que dichas etiquetas aparecen en el *tag set*. Se reserva el 2 como comodín para el resto de etiquetas del *tag set*.

Por tanto el mini-diccionario y el mini-tag-set contendrán el *mapping* de todos los símbolos que participan en las reglas que nos servirán para la creación de los *FST*,s. Es decir, finalmente tendremos algo del estilo:

PR	palabras $\notin$ PR	Inicio de frase	Epsilon	Fin de frase	etiquetas $\notin$ ER	ER
-m, ..., -4, -3	-2	-1	0	1	2	3, 4, ..., n

donde PR y ER son los conjuntos de palabras y etiquetas que participan en las reglas, respectivamente.

Cuando tengamos todos los traductores creados, uno para cada regla contextual, los combinaremos para obtener un único traductor. Para poderlo poner en funcionamiento necesitamos una entrada, que estará formada por una frase y su enrejado correspondiente, donde las etiquetas del enrejado deben estar ordenadas en función de cómo aparecen en el *tag set*. Para poder darle la entrada al traductor necesitamos hacer un *mapping* de la entrada original a una entrada equivalente, que entienda el traductor, y que vendrá determinada en función del mini-diccionario y del mini-tag-set. Una vez que el traductor haya procesado la entrada y dé una salida, ésta deberá ser igualmente transformada a su nuevo enrejado equivalente. Este proceso se refleja claramente en la figura 6.2.

Para adaptar la entrada actuamos de la siguiente manera:

Figura 6.2: Proceso de ejecución.

- Para cada palabra de la frase de entrada a etiquetar realizamos la siguiente comprobación: si la palabra está en nuestro mini-diccionario, le asignamos el número negativo correspondiente; de no ser así, le asignamos el comodín (-2).

- Para cada columna de etiquetas del enrejado procedemos de la siguiente manera. Cogemos cada una de las etiquetas y miramos si está en el mini-tag-set. Si es así nos quedamos con el número positivo asociado. Si no es así, le asignamos el comodín (2).

La entrada para el traductor estará delimitada por los caracteres especiales de principio y fin de frase, -1 y 1 respectivamente, y estará formada por un número negativo que representa a una palabra y por todas sus etiquetas posibles, que se corresponden con números positivos. Aquí merece la pena comentar que el comodín podría aparecer una o más veces, pero para simplificar la operación de los traductores, lo tenemos en cuenta una única vez. Esto no va a repercutir en el funcionamiento correcto del traductor, y así tendremos el conjunto de etiquetas de la entrada del traductor ordenado de menor a mayor. Por ejemplo, tendremos una entrada del estilo:

-1	-5	4	7	9	-2	2	5	7	...	-4	3	6	8	1
Inicio frase	Palabra	Etiquetas			Palabra	Etiquetas			...	Palabra	Etiquetas			Fin frase

Este proceso tendrá que repetirse de forma inversa una vez obtenida la salida del traductor. Cabe destacar que hay que guardar la correspondencia de los números con sus etiquetas para reconstruir el enrejado de salida. Sobre todo, hay que tener cuidado con aquellas etiquetas que se correspondan con los comodines. La forma de actuar consiste en, partiendo de la secuencia de salida del traductor comprobar si ésta ha variado con respecto a la entrada. Para ello, de la salida se coge una palabra con sus etiquetas correspondientes y se mira en la secuencia de entrada si se han producido cambios. Si es así, se construye el nuevo enrejado en función de los mismos. Si no hay cambios, el enrejado queda tal cual. En caso de haber comodines, como sólo va a aparecer uno, se comprueba si había o no varios en el enrejado de entrada equivalente. Si los había, se deberán tener todos en cuenta y escribir sus etiquetas correspondientes.

Ejemplo 6.2 Consideremos el siguiente conjunto de reglas contextuales[3]:

```
SELECCIONA (D) (−1 ES {V}, 0 PERTENECE {el}, 1 CONTIENE {S});
BORRA (S) (−1 ES {D}, 1 PERTENECE {encima,sobre});
FUERZA (P) (−1 ES {S}, 2 ES {S});
SELECCIONA (V) (−1 ES {S},0 PERTENECE {dejar,fue,vino});
```

El mini-diccionario y el mini-tag-set asociados serán:

[3]Para todos los ejemplos consideraremos las siguientes abreviaturas para representar las etiquetas:
Adj → Adjetivo. P → Preposición. S → Sustantivo.
D → Determinante. Pron → Pronombre. V → Verbo.

Mini-diccionario		Mini-tag-set	
dejar	−3	D	3
el	−4	P	4
encima	−5	S	5
fue	−6	V	6
sobre	−7		
vino	−8		

Supongamos que tenemos como enrejado de entrada:

María	vino	para	dejar	el	bajo	sobre	la	mesita	pequeña
S	S	P	V	D	P	S	D	S	Adj
	V			Pron	S				

El enrejado equivalente teniendo en cuenta el mini-diccionario y el mini-tag-set sería:

−2	−8	−2	−3	−4	−2	−7	−2	−2	-2
5	5	4	6	3	4	5	3	5	2
	6			2	5				

Y la entrada para el traductor tendrá el formato indicado a continuación:

$$-1,-2,5,-8,5,6,-2,4,-3,6,-4,2,3,-2,4,5,-7,5,-2,3,-2,5,-2,2,1$$

Si obtuviéramos como salida:

$$-1,-2,5,-8,6,-2,4,-3,6,-4,3,4,-2,5,-7,4,-2,3,-2,5,-2,2,1$$

llevaríamos a cabo el *mapping* inverso. Para la primera palabra vemos que no se han producido cambios, entonces queda todo tal cual. En cambio para la segunda palabra vemos que se ha producido un cambio, y no participan comodines, entonces nos quedamos con los cambios. Para la última palabra vemos que no se han producido cambios y que nos encontramos con un comodín como etiqueta, entonces recuperamos la etiqueta que representa dicho comodín. Los enrejados resultantes, con y sin *mapping*, serían:

−2	−8	−2	−3	−4	−2	−7	−2	−2	-2
5	6	4	6	3	5	4	3	5	2

María	vino	para	dejar	el	bajo	sobre	la	mesita	pequeña
S	V	P	V	D	S	P	D	S	Adj

□

6.2.2 Construcción de los traductores de estado finito

A continuación vamos a ver los traductores de estado finito que representan los esquemas generales de reglas. No vamos a mostrar todos por el gran número de esquemas de reglas posibles, pero si indicaremos los más interesantes y significativos.

1. Reglas locales:
   Existen muchas combinaciones posibles para este tipo de reglas, tal y como se puede ver en el capítulo anterior, pero analizaremos las siguientes:

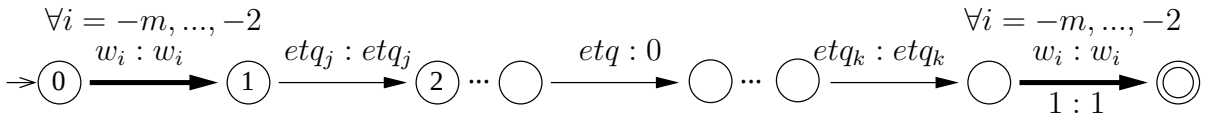

Figura 6.3: *FST* para: `BORRA` (etq) $(0$ `ES` $\{etq_j, ..., etq, ..., etq_k\})$;

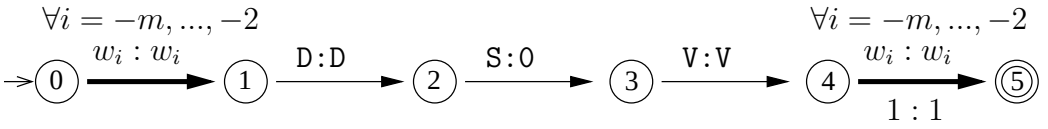

Figura 6.4: *FST* para: `BORRA (S) (0 ES {D,S,V});`

- **BORRA** (etq) $(0$ **ES** $\{etq_j, ..., etq, ..., etq_k\})$**;**
  Esta regla nos dice que la palabra actual no puede tener como etiqueta etq si sus etiquetas posibles son exactamente las indicadas en el conjunto de etiquetas de la regla $\{etq_j, ..., etq, ..., etq_k\}$.
  El traductor que simula el funcionamiento de esta regla se muestra en la figura 6.3. De este traductor caben mencionar los siguientes puntos:
  - En cuanto a la topología de este y de futuros traductores, es necesario aclarar que las transiciones que representan palabras se dibujan con una flecha más gruesa para facilitar la lectura. Después de cada palabra nos encontraremos con una o más transiciones que representan etiquetas, donde por lo menos debe aparecer una, ya que en el enrejado de entrada no puede aparecer ninguna palabra sin etiquetas asignadas. También con la intención de facilitar la comprensión de todos estos traductores, los símbolos que aparecen en las transiciones pueden hacer referencia a las palabras y etiquetas concretas. No obstante, debe quedar claro que los traductores reales trabajarán internamente sólo con los números enteros obtenidos a partir del *mapping* correspondiente. De momento, en estos primeros ejemplos y esquemas generales de traductores, allí donde no aparezca un número entero concreto, utilizaremos w_i para hacer referencia a las palabras y etq_i para hacer referencia a las etiquetas. En el caso de los w_i, el subíndice i podrá variar desde -2 hasta $-m$, siendo w_{-2} el comodín para palabras. Y en el caso de los etq_i, el subíndice i podrá variar desde 2 hasta n, siendo etq_2 el comodín para etiquetas.
  - La acción de borrado en el traductor se refleja transformando la etiqueta en cuestión en un *epsilon*, que se representa con un 0.
  - La condición de igualdad consiste en dibujar una transición por cada etiqueta que aparece en el conjunto de etiquetas de la regla. En dicha transición, los símbolos de entrada y salida están constituidos por la propia etiqueta.
  - La última transición del traductor nos dice que después de la última etiqueta forzosamente debe aparece o bien una palabra o bien el fin de frase.

Ejemplo 6.3 Consideremos la siguiente regla:

```
BORRA (S) (0 ES {D,S,V});
```

Esta regla dice que si las etiquetas posibles para la palabra actual son *determinante*, *sustantivo*, y *verbo* entonces nunca será *sustantivo*. El traductor de estado finito correspondiente se muestra en la figura 6.4.

□

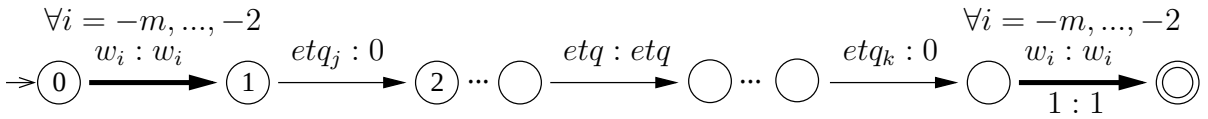

Figura 6.5: *FST* para: `SELECCIONA` (*etq*) (0 `ES` {$etq_j, ..., etq, ..., etq_k$});

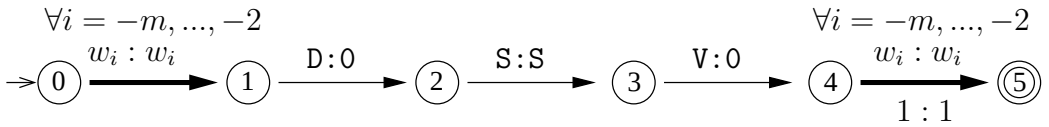

Figura 6.6: *FST* para: `SELECCIONA (S) (0 ES {D,S,V});`

- **SELECCIONA** (*etq*) (0 **ES** {$etq_j, ..., etq, ..., etq_k$});
  Esta regla dice que la etiqueta de la palabra actual es *etq* si sus etiquetas posibles son exactamente las indicadas en el conjunto {$etq_j, ..., etq, ..., etq_k$}.
  El traductor equivalente se muestra en la figura 6.5. De este traductor, indicamos únicamente que la acción de selección se lleva a cabo transformando las etiquetas que no son susceptibles de ser seleccionadas en *epsilon*, dejando como está la relevante.

  Ejemplo 6.4 Consideremos la siguiente regla:

  `SELECCIONA (S) (0 ES {D,S,V});`

  Esta regla nos dice que la palabra actual es un *sustantivo*, si las etiquetas posibles para ella son *determinante*, *sustantivo* y *verbo*. El traductor que se corresponde con esta regla se muestra en la figura 6.6.

  □

- **FUERZA** (*etq*) (0 **ES** {$etq_j, ..., etq_k$});
  Es decir, la etiqueta de la palabra actual se fuerza a *etq* si sus etiquetas posibles son exactamente el conjunto de etiquetas {$etq_j, ..., etq_k$}. Destacar que la etiqueta a forzar no es ninguna de las que están *a priori*.
  Su traductor de estado finito correspondiente es el de la figura 6.7. En este traductor, la acción consiste en transformar un *epsilon* en la etiqueta a forzar, poniendo el resto de etiquetas a *epsilon*.

  Ejemplo 6.5 Consideremos la siguiente regla:

  `FUERZA (S) (0 ES {A,D,V});`

  La palabra actual es un *sustantivo* si tiene como etiquetas posibles *artículo*, *determinante* y *verbo*. El traductor equivalente se muestra en la figura 6.8.

  □

- **BORRA** (*etq*) (**NOT** 0 **ES** {$etq_j, etq_k..., etq_l$});
  Es decir, la palabra actual no puede tener como etiqueta *etq* si su conjunto de

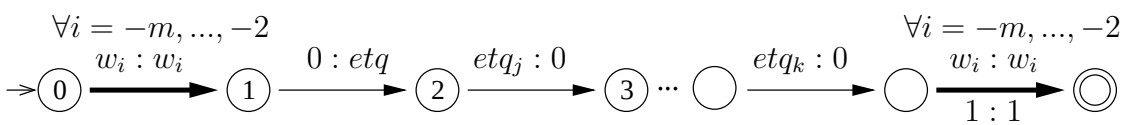

Figura 6.7: *FST* para: `FUERZA` (*etq*) (0 `ES` {$etq_j, ..., etq_k$});

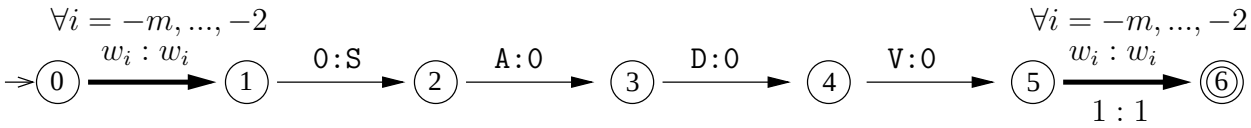

Figura 6.8: *FST* para: `FUERZA (S) (0 ES {A,D,V});`

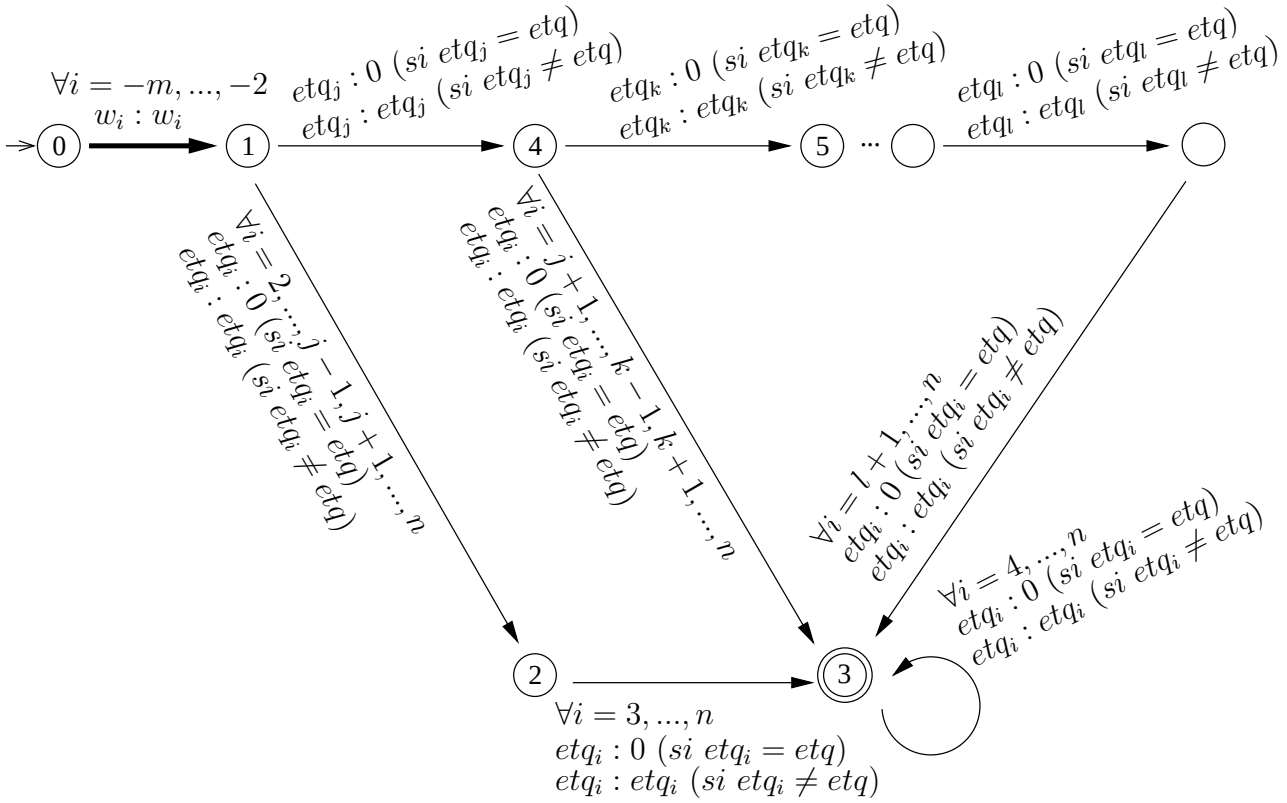

Figura 6.9: *FST* para: `BORRA` (etq) `(NOT 0 ES` $\{etq_j, etq_k..., etq_l\}$`);`

etiquetas posibles no es exactamente el indicado en el conjunto de etiquetas de la regla $\{etq_j, etq_k..., etq_l\}$.
El traductor correspondiente es el que se muestra en la figura 6.9. Como podemos observar, el NOT complica el diseño del traductor. Lo que se representa básicamente es la no aparición exacta del conjunto de etiquetas de la regla, pero lo que sí pueden aparecer son subconjuntos de él con o sin más etiquetas, y superconjuntos de él. De esta manera el camino superior del grafo identifica el conjunto de etiquetas de la regla, y muere en un estado que no es final si se cumple la igualdad.

Ejemplo 6.6 Consideremos la siguiente regla:

```
BORRA (V) (NOT 0 ES {Adj});
```

La palabra actual no puede ser un *verbo* si no tiene a *adjetivo* como etiqueta. El traductor equivalente se muestra en la figura 6.10.

□

- **FUERZA** (etq) $(n > 0$ **ES** $\{etq_j, ..., etq_k\})$**;**
  Es decir, la palabra actual se fuerza a que tenga etq como etiqueta si la palabra

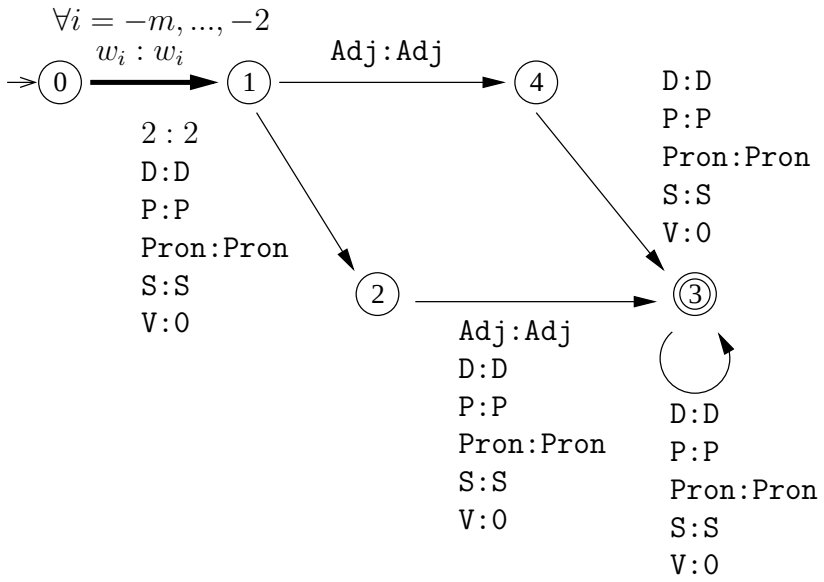

Figura 6.10: *FST* para: `BORRA (V) (NOT 0 ES {Adj});`

que está n posiciones más adelante respecto a la palabra considerada tiene como etiquetas posibles exactamente las indicadas en el conjunto de etiquetas de la regla $\{etq_j, ..., etq_k\}$.
El traductor que se corresponde con este esquema de reglas se encuentra en la figura 6.11. En este caso como la condición se refiere a una palabra distinta de la considerada, tenemos que construir un traductor que pase por todas las palabras pertinentes, dejándolo todo tal y como está, hasta llegar a la palabra afectada por la condición. Al tratarse de un n positivo, entonces la acción de la regla se realiza al principio del traductor y a continuación se pasa por todas las palabras necesarias hasta llegar a la palabra donde se comprueba la condición. Si por el contrario, el número n fuese negativo, el proceso sería inverso, es decir, se le daría la vuelta al traductor de manera que lo primero que se tendría en cuenta sería la condición de la regla, para después pasar por las palabras necesarias hasta llegar a la actual donde se llevaría a cabo la acción.

Ejemplo 6.7 Consideremos la siguiente regla:

`FUERZA (S) (1 ES {Adj});`

La palabra actual es forzosamente un *sustantivo* si la siguiente es un *adjetivo*. El traductor para esta regla se muestra en la figura 6.12.

□

- **BORRA** (etq) $(0$ **CONTIENE** $\{etq_j, etq_k..., etq_l\})$**;**
  Es decir, la palabra actual no tendrá etq como etiqueta si entre sus etiquetas posibles nos encontramos las que aparecen en el conjunto de etiquetas de la regla $\{etq_j, etq_k..., etq_l\}$ y alguna más.
  El traductor que simula el comportamiento de este esquema de reglas es el indicado en la figura 6.13. Y de él vale la pena destacar la condición de inclusión, donde se tiene en cuenta la aparición de las etiquetas de la regla y, por lo menos, una más, ya que no se permite la condición de igualdad. El orden de las etiquetas es importante

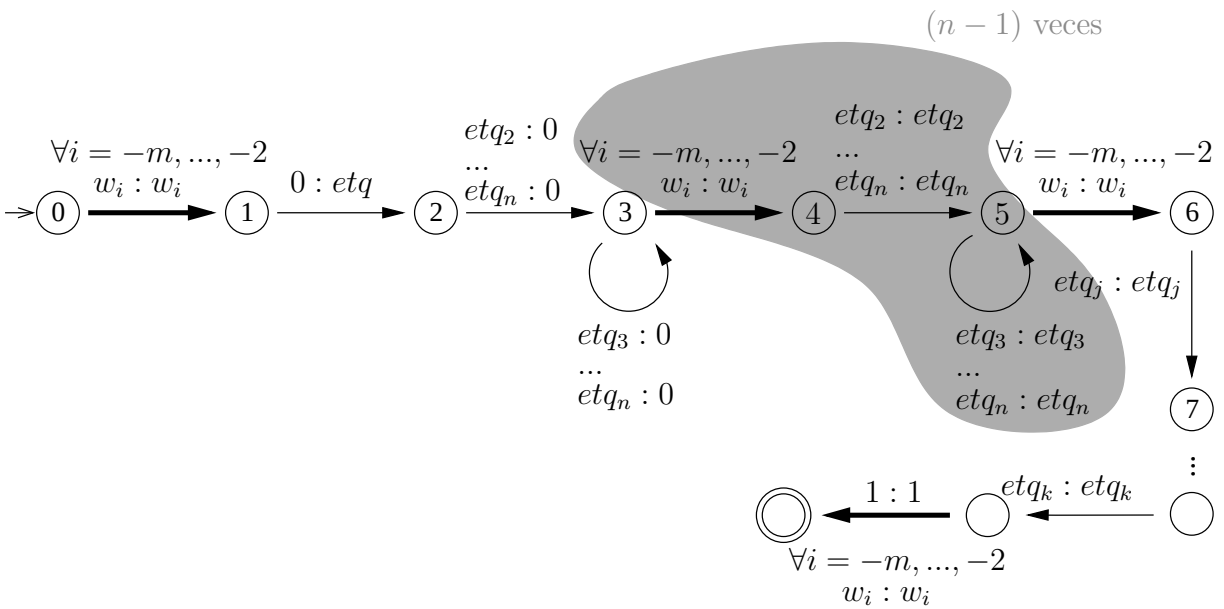

Figura 6.11: *FST* para: `FUERZA` (etq) $(n > 0$ `ES` $\{etq_j, ..., etq_k\})$`;`

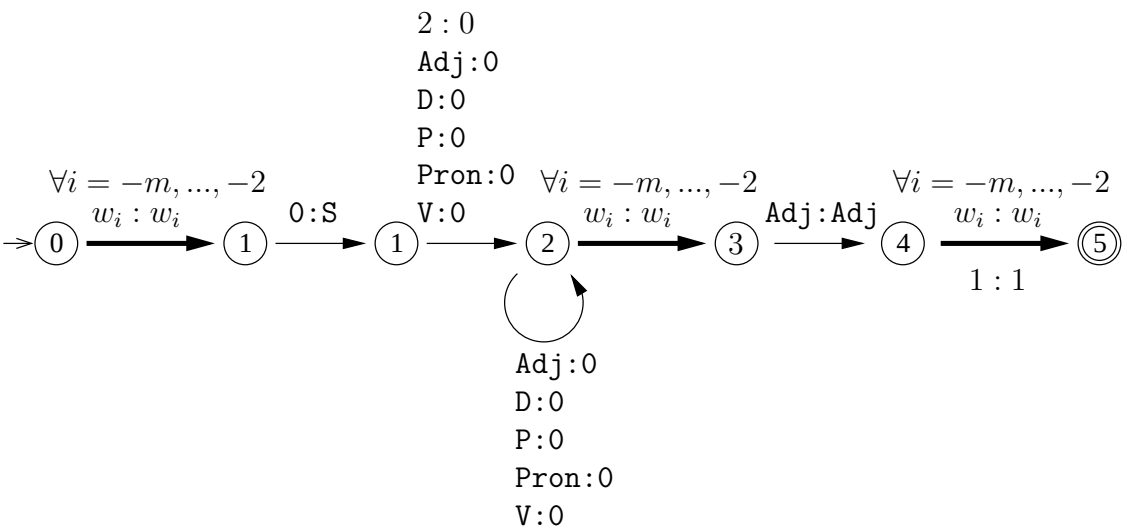

Figura 6.12: *FST* para: `FUERZA (S) (1 ES {Adj});`

en este formalismo y también hay que tenerlo en cuenta aquí. No obstante, esto permitirá que, en general, la complejidad en el diseño de los traductores sea menor.

Ejemplo 6.8 Consideremos la siguiente regla:

```
BORRA (D) (0 CONTIENE {Pron,V});
```

La palabra actual no puede ser un *determinante* si entre sus etiquetas nos encontramos con un *pronombre* y un *verbo* como posibilidades. El traductor de estado finito equivalente es el de la figura 6.14.

□

- **SELECCIONA** (etq_e) (**NOT** $n > 0$ **CONTIENE** $\{etq_j, etq_k, ..., etq_h, etq_l\}$);
  Es decir, la palabra actual tendrá como etiqueta a etq_e siempre y cuando la palabra de n posiciones hacia adelante no tiene entre sus etiquetas el conjunto de etiquetas $(etq_j, etq_k, ..., etq_h, etq_l)$.
  El traductor correspondiente a este esquema de reglas es el que se muestra en la figura 6.15. Como se puede ver la topología de este traductor es algo complicada.

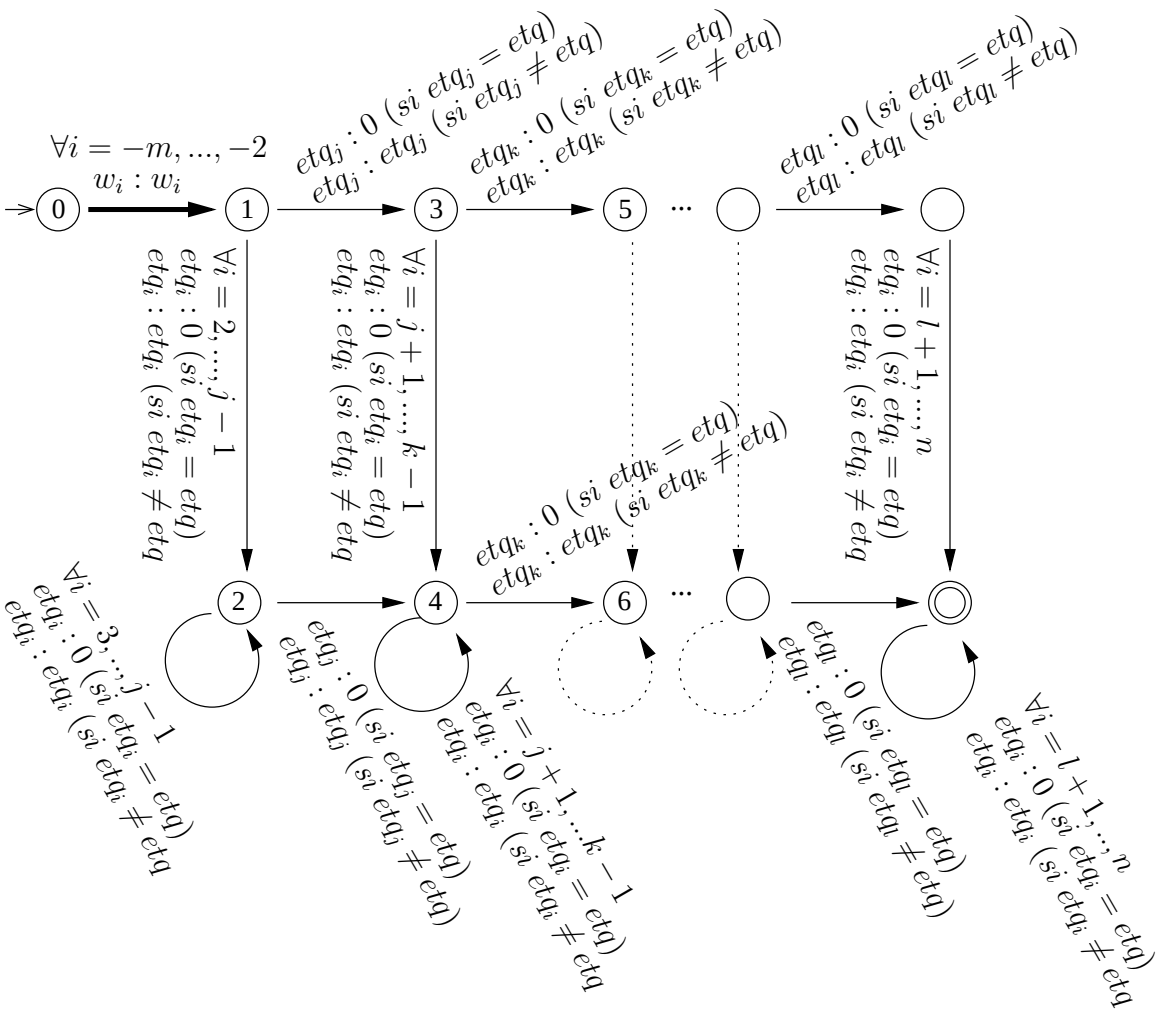

Figura 6.13: Traductor para: `BORRA` (etq) (0 `CONTIENE` $\{etq_j, etq_k..., etq_l\}$);

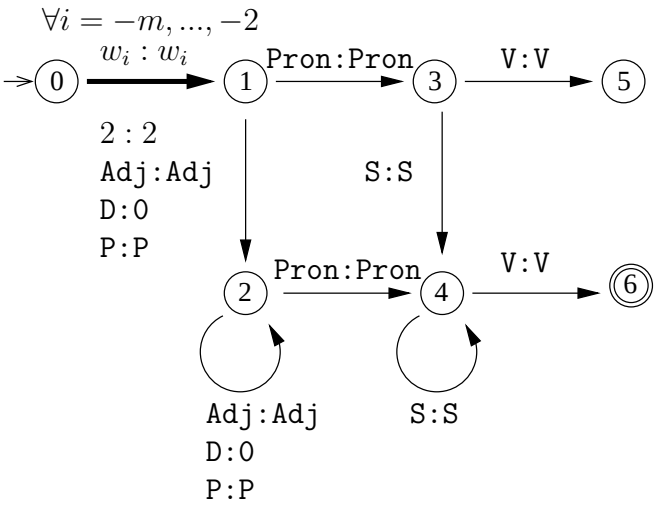

Figura 6.14: Traductor para: `BORRA (D) (0 CONTIENE {Pron,V});`

Esta complejidad principalmente viene determinada por la negación de la continencia, de forma que la negación de $A \supset B$ es $A \subseteq B$, siendo A el conjunto de etiquetas de la palabra afectada por la condición, y siendo B el conjunto de etiquetas de dicha condición en la regla. Analizando un poco la situación, se puede ver que la condición de la regla será falsa únicamente para aquellos conjuntos A que contengan a B entre sus elementos, y en el resto de los casos la condición de la regla será verdadera. Es decir, la condición se cumple para todos los conjuntos que contengan a algún elemento del conjunto de partes del conjunto B, *P(B)*[4], menos para el propio conjunto B, en el que únicamente se permite la igualdad. Veámoslo con un pequeño ejemplo para aclarar un poco más esta idea. Supongamos que $B = \{1, 2, 3\}$, entonces:

	Verdadero	**Falso**
`CONTIENE` $A \supset B$	$A = \{1, 2, 3, ...\}$	$A = \{\varnothing, ...\}$ $A = \{1, ...\}$ $A = \{2, ...\}$ $A = \{3, ...\}$ $A = \{1, 2, ...\}$ $A = \{1, 3, ...\}$ $A = \{2, 3, ...\}$ $A = \{1, 2, 3\}$
`NOT CONTIENE` $A \subseteq B$	$A = \{\varnothing, ...\}$ $A = \{1, ...\}$ $A = \{2, ...\}$ $A = \{3, ...\}$ $A = \{1, 2, ...\}$ $A = \{1, 3, ...\}$ $A = \{2, 3, ...\}$ $A = \{1, 2, 3\}$	$A = \{1, 2, 3, ...\}$

[4]Sea C un conjunto cualquiera. Se llama *conjunto de partes del conjunto C*, escrito *P(C)*, al conjunto cuyos elementos son todos los subconjuntos posibles del conjunto C.
Así, con C={a,b,c} se tiene que:

P(B) = {∅,{a},{b},{c},{a,b},{a,c},{b,c},{a,b,c}}

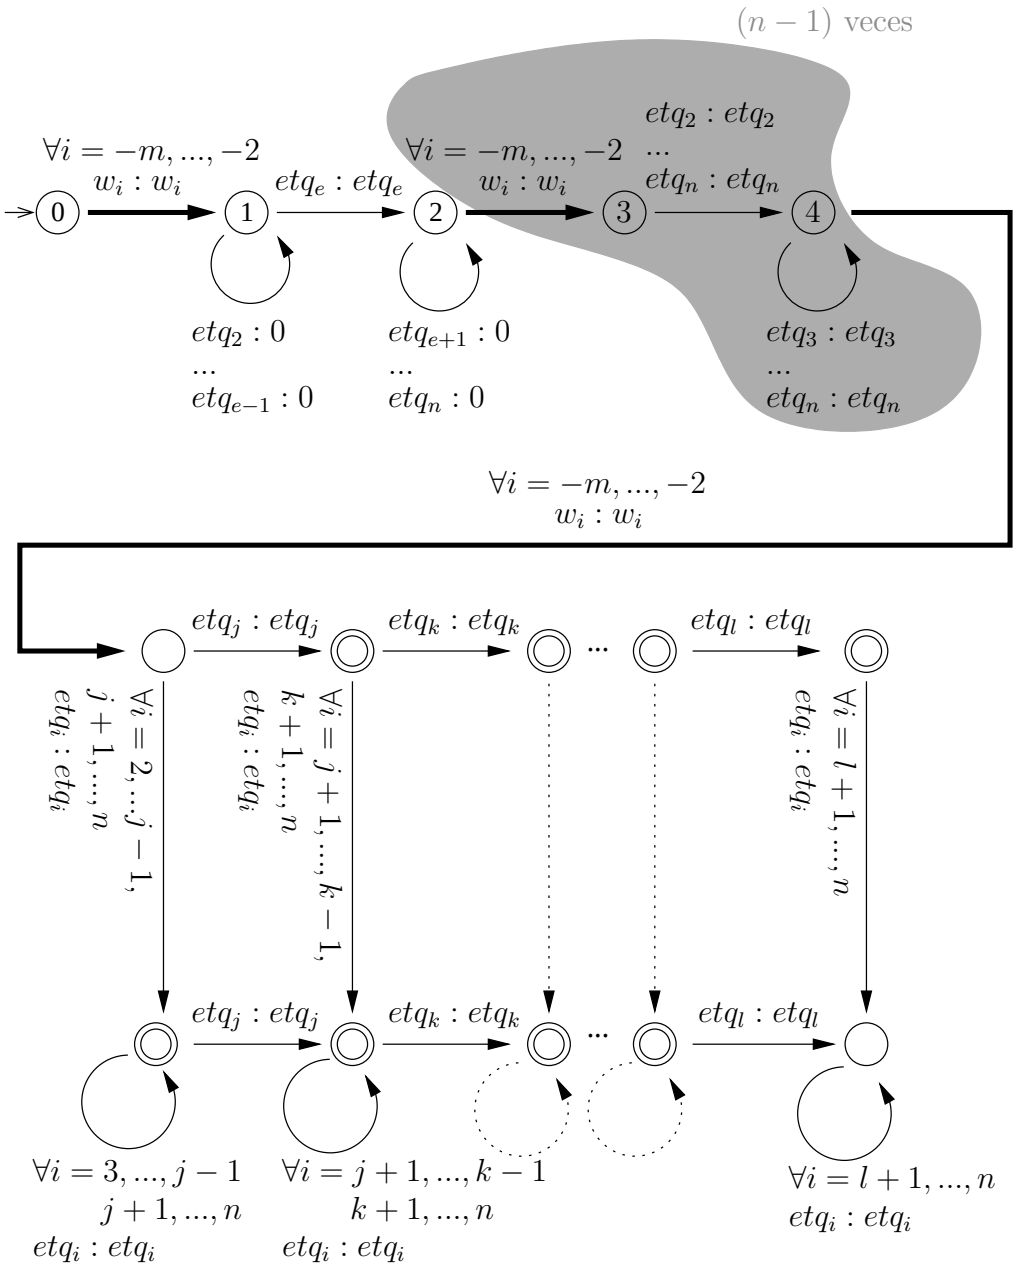

Figura 6.15: *FST* para: `SELECCIONA` (etq_e) (`NOT` $n > 0$ `CONTIENE` $\{etq_j,\ etq_k, ...,\ etq_l\}$);

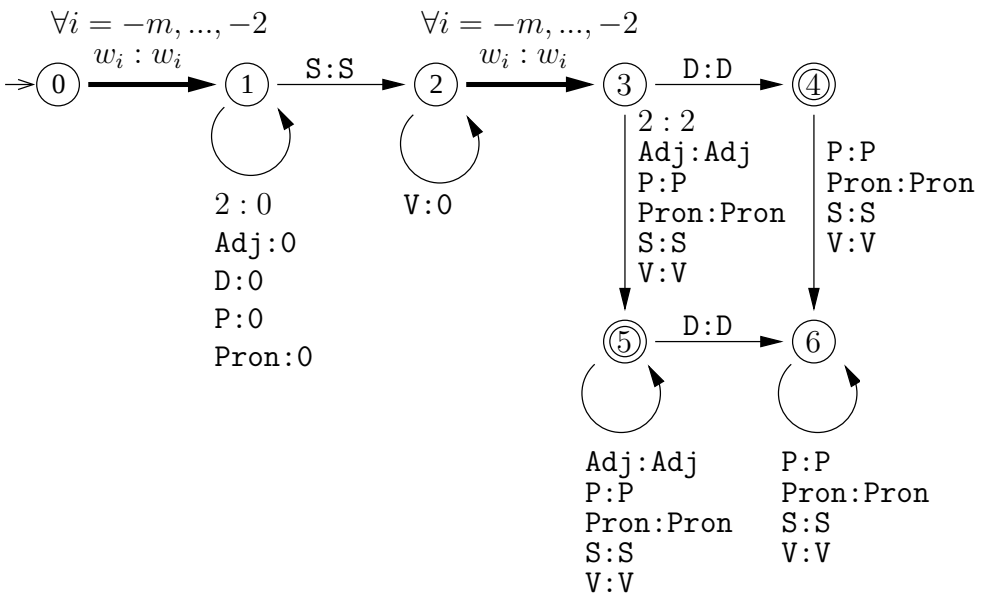

Figura 6.16: Traductor para: `SELECCIONA (S) (NOT 1 CONTIENE {D});`

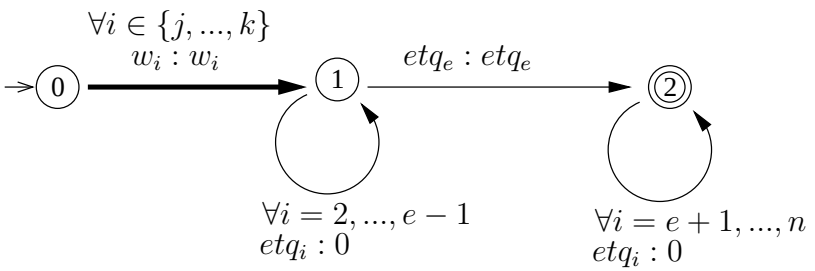

Figura 6.17: *FST* para: `SELECCIONA` (etq_e) $(0$ `PERTENECE` $\{w_j, ..., w_k\})$;

Ejemplo 6.9 Consideremos la siguiente regla:

```
SELECCIONA (S) (NOT 1 CONTIENE {D});
```

La palabra actual es un *sustantivo* si la siguiente palabra no puede ser un *determinante*. Esta regla se muestra en la figura 6.16

□

- **SELECCIONA** (etq_e) $(0$ **PERTENECE** $\{w_j, ..., w_k\})$**;**
  Es decir, la palabra actual tiene como etiqueta etq_e si es alguna de las que aparece en el conjunto de palabras de la regla $\{w_j, ..., w_k\}$.
  El traductor correspondiente se muestra en la figura 6.17. De él solamente indicamos que la condición de pertenencia para las palabras complica poco el diseño del traductor ya que únicamente se van a tener en cuenta aquellas palabras que aparecen en la regla, en lugar de todas las del mini-diccionario como se venía haciendo hasta ahora, y se van a ejecutar la acciones adecuadas en las etiquetas correspondientes.

Ejemplo 6.10 Consideremos la siguiente regla:

```
SELECCIONA (V) (0 PERTENECE {es,fue,tiene});
```

Si la palabra actual es alguna del conjunto {es,fue,tiene}, entonces su etiqueta es *verbo*. El traductor correspondiente es el de la figura 6.18.

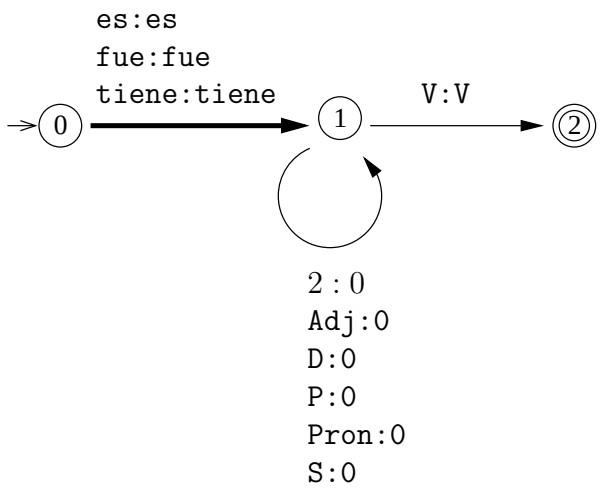

Figura 6.18: *FST* para: `SELECCIONA (V) (0 PERTENECE {es,fue,tiene});`

□

2. Reglas barrera:
   Para este tipo de reglas también nos podemos encontrar con una gran variedad debido a los distintos tipos de condición que permitimos. Sin embargo, únicamente vamos a hacer hincapié en una sola regla. El lector puede fácilmente deducir los traductores de estado finito asociados al resto de las reglas ayudándose de las indicaciones del apartado anterior y de este.

   - **SELECCIONA** (etq_e) $(+*$ **ES** $\{etq_j, etq_k, ..., etq_l\}$ $<$ **BARRERA** $>$ **ES** $\{etq_x, etq_y, ..., etq_z\})$**;**
     Es decir, si antes de una palabra nos encontramos con otra cuyas etiquetas se corresponden exactamente con el conjunto de etiquetas $\{etq_j, etq_k, ..., etq_l\}$ y, entre ambas palabras no hay ninguna otra cuyo conjunto de etiquetas sea exactamente $\{etq_x, etq_y, ..., etq_z\}$, entonces esa palabra tendrá a etq_e como etiqueta.
     El traductor de estado finito asociado con este esquema de reglas es el que se muestra en la figura 6.19. El diseño de este traductor es ligeramente complicado, tal y como se puede apreciar en la figura, donde se tienen en cuenta tres caminos alternativos, uno que se corresponde con la primera condición, otro que se corresponde con la segunda condición, y por último otro donde se considerarán el resto de las etiquetas del mini-tag-set. Otro factor que resulta interesante comentar es la necesidad de un lazo para completar la lógica de la regla, ya que se desconoce el número de palabras por la que es necesario navegar para determinar la resolución de las condiciones. Indicamos también que en este caso la acción de la regla se lleva a cabo al principio del traductor debido a que la dirección de ejecución es hacia la derecha $(+*)$. Sin embargo, si elegimos la dirección de ejecución contraria, hacia la izquierda $(-*)$, entonces la acción de la regla se llevará a cabo en las últimas transiciones del traductor.

     Ejemplo 6.11 Consideremos la siguiente regla:

     `SELECCIONA (V) (+* ES {S,P} <BARRERA> ES {D});`

     Si antes de una palabra hay otra que tiene la posibilidad de ser *sustantivo* o *verbo* y entre ambas palabras no hay ninguna que pueda ser *determinante*, entonces esa

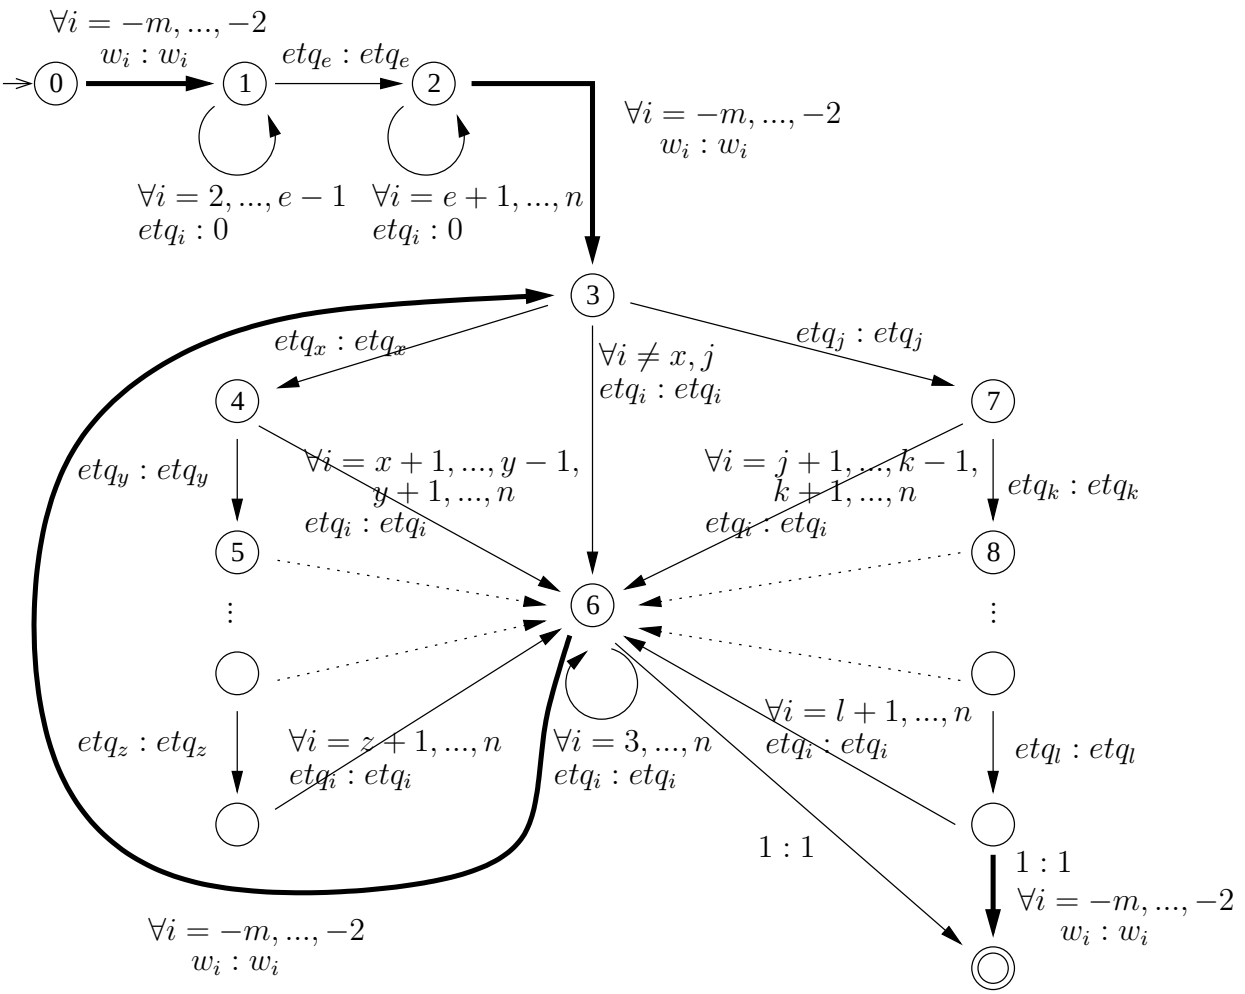

Figura 6.19: *FST* para: `SELECCIONA` (etq_e) $(+*$ `ES` $\{etq_j,\ etq_k,\ ...,\ etq_l\}$ $<$ `BARRERA` $>$ `ES` $\{etq_x,\ etq_y,\ ...,\ etq_z\})$;

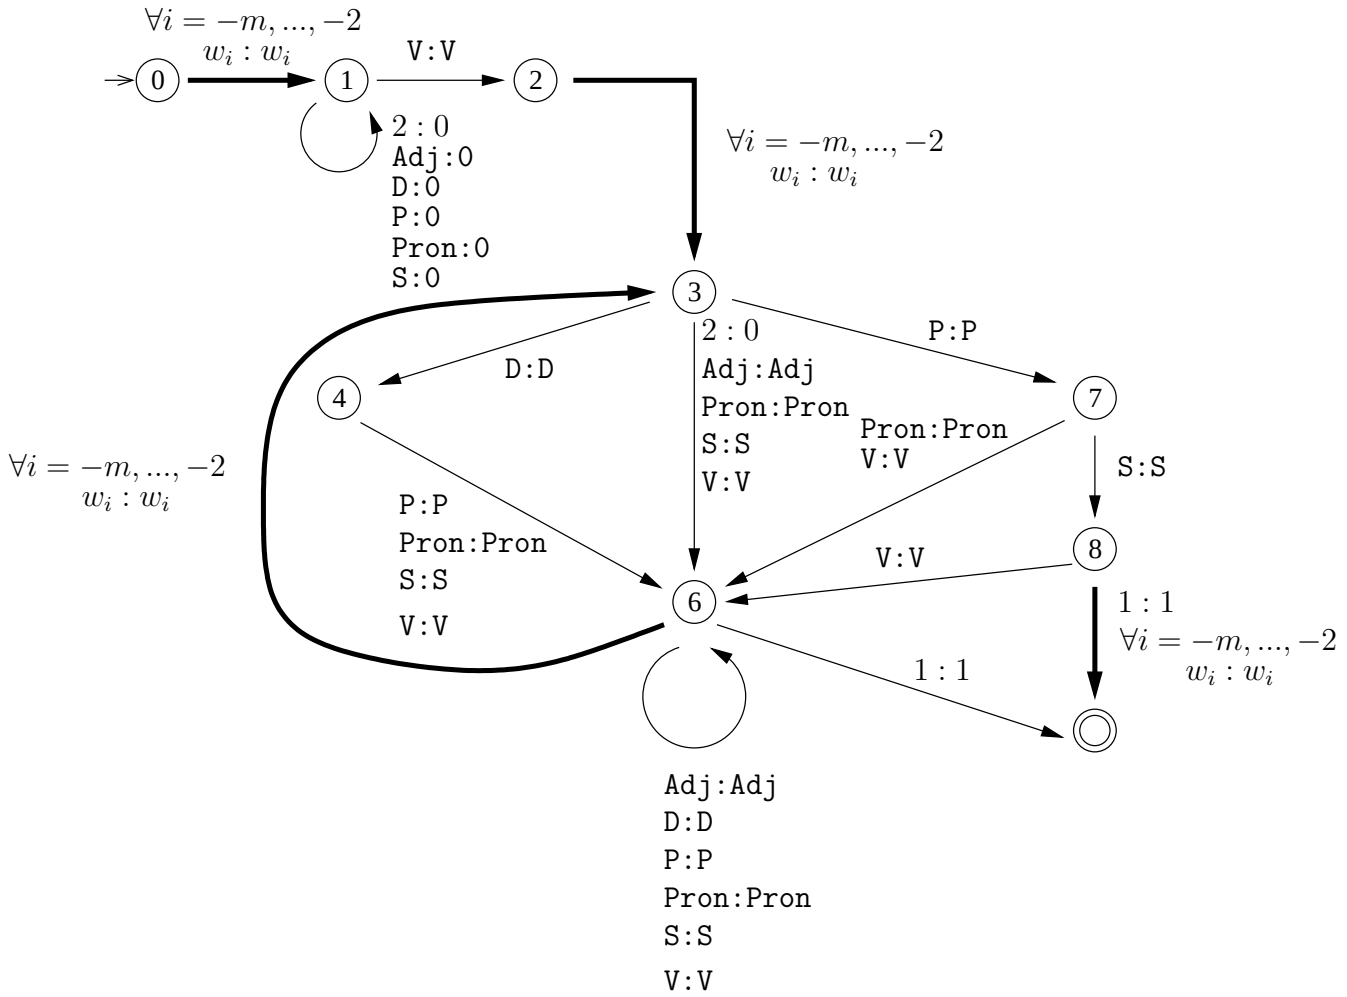

Figura 6.20: *FST* para: `SELECCIONA (V) (+* ES {S,P} <BARRERA> ES {D});`

palabra será un *verbo*. El traductor equivalente se muestra en la figura 6.20.

□

6.3 Modo de operación de los traductores de estado finito

Llegados a este punto, donde ya tenemos los *FST*,s para cada regla, nos queda por crear y compilar cada traductor por separado para después combinarlos de manera que al final obtengamos un único traductor que simula el comportamiento de aplicar todas las reglas de forma secuencial. Hasta ahora hemos trabajado con las etiquetas y las palabras involucradas en las reglas con el propósito de facilitar la lectura del documento, sin embargo realmente los traductores van a estar formados por los símbolos que resultan del *mapping* de las reglas, y no de las palabras y etiquetas en sí, tal y como se introdujo en el apartado 6.2.1. A continuación los ejemplos se detallarán de las dos maneras para facilitar su comprensión, pero debe quedar claro que en la realidad sólo se construirán los traductores correspondientes utilizando el *mapping* en cuestión.

6.3.1 Creación de los traductores de estado finito

Los traductores de estado finito se van a representar a través de ficheros de texto, de manera que tendremos un fichero de texto por cada traductor. Las líneas que lo forman se van a corresponder con transiciones del traductor a representar, de manera que tendremos tantas líneas en el fichero como transiciones existentes en el traductor. En cada línea se especificarán los siguientes campos: estado origen, estado destino, símbolo de entrada y símbolo de salida, todos ellos separados por un espacio en blanco. El estado origen será el primero en aparecer, mientras que el estado destino se especifica al final del fichero. Los símbolos de las transiciones, se van a corresponder con números negativos o positivos según hablemos de palabras o etiquetas, y se corresponderán con el *mapping* de las palabras y etiquetas que aparecen en el mini-diccionario y en el mini-tag-set, respectivamente, según se indicó en el apartado 6.2.1.

Además de los traductores también necesitamos especificar el alfabeto con el que vamos a trabajar, y para ello es necesario crear un fichero de símbolos donde se especificarán todos aquellos elementos que participan en las transiciones de los traductores y que hemos referenciado en los ficheros de texto. De esta manera el fichero de símbolos tendrá tantas líneas como elementos existan en el mini-diccionario más en el mini-tag-set más los símbolos especiales -2, -1, 0, 1 y 2. En cada línea se especificarán un número positivo y un símbolo, ambos separados por un espacio en blanco, donde este número positivo será la representación interna del símbolo. Por último indicar que a cada uno de los ficheros de texto que representen a los traductores se le pondrá extensión `.stxt` y al fichero de símbolos que representa al alfabeto se le pondrá extensión `.syms`.

Ejemplo 6.12 Para reflejar todas estas ideas retomemos el ejemplo 6.2 tratado en el apartado 6.2.1, donde nos encontrábamos con cuatro reglas. Para simplificar el problema supongamos que sólo tenemos la primera regla, siguiendo tal cual el mini-diccionario y el mini-tag-set:

```
SELECCIONA (D) (−1 ES {V}, 0 PERTENECE {el}, 1 CONTIENE {S});
```

Mini-diccionario		**Mini-tag-set**	
dejar	-3	D	3
el	-4	P	4
encima	-5	S	5
fue	-6	V	6
sobre	-7		
vino	-8		

El traductor de estado finito correspondiente es el que se muestra en la figura 6.21. Utilizando los símbolos que resultan del *mapping* de las palabras y de las etiquetas, el traductor resultante es el mismo cambiando únicamente la palabras por números negativos y las etiquetas por números positivos, tal y como se indica en el mini-diccioario y en el mini-tag-set respectivamente. Este traductor se muestra en la figura 6.22.

A partir de este último traductor, el de la figura 6.22, creamos el fichero de texto que lo representa. Y a partir del mini-diccionario y del mini-tag-set se crea el fichero de símbolos correspondiente.

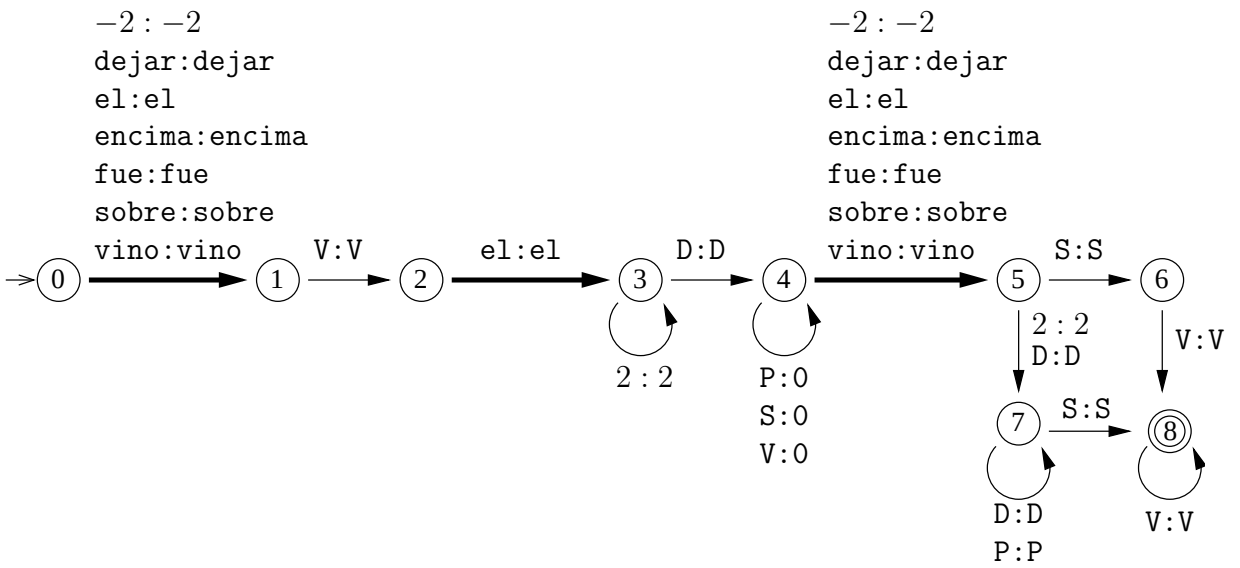

Figura 6.21: *FST* de la regla: `SELECCIONA (D) (−1 ES {V}, 0 PERTENECE {el}, 1 CONTIENE {S});`

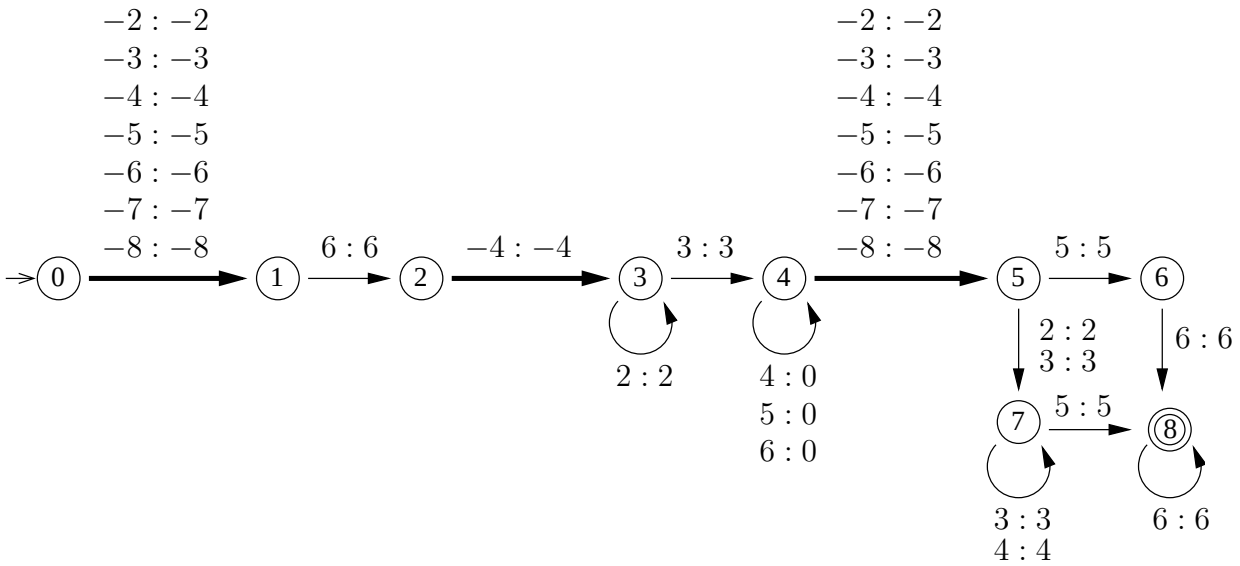

Figura 6.22: *FST* mapeado de la regla: `SELECCIONA (D) (−1 ES {V}, 0 PERTENECE {el}, 1 CONTIENE {S});`

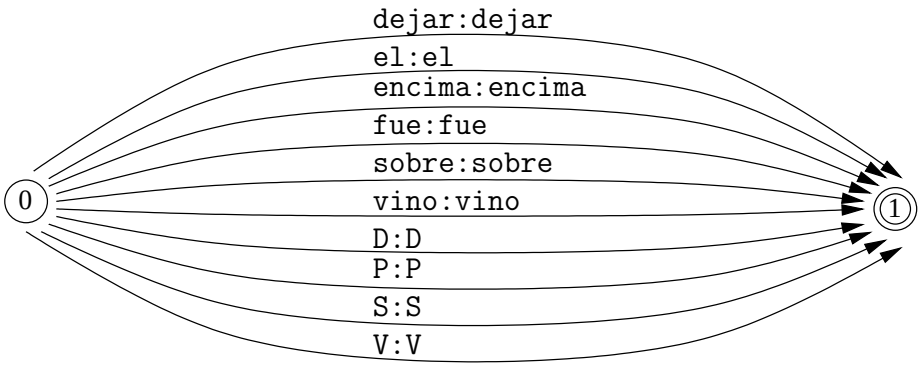

Figura 6.23: *FST* del alfabeto

traductorEjemplo.stxt				alfabeto.syms	
0	1	−3	−3	0	0
0	1	−4	−4	−11	1
0	1	−5	−5	−3	2
0	1	−6	−6	−4	3
0	1	−7	−7	−5	4
0	1	−8	−8	−6	5
1	2	6	6	−7	6
2	3	−4	−4	−8	7
3	4	3	3	1	8
4	4	4	0	3	9
4	4	5	0	4	10
4	4	6	0	5	11
4	5	−3	−3	6	12
4	5	−4	−4		
4	5	−5	−5		
4	5	−6	−6		
4	5	−7	−7		
4	5	−8	−8		
5	6	5	5		
5	7	3	3		
7	7	4	4		
7	8	6	6		
8					

Para el alfabeto también es necesario construir un traductor de estado finito, y éste es el que se muestra en la figura 6.23. Su traductor real equivalente utilizando los símbolos que resultan del *mapping* de las palabras y de las etiquetas es el que se indica en la figura 6.24. De aquí vale la pena comentar que además de los símbolos que participan en las reglas también tenemos que tener en cuenta los símbolos de principio y fin de frase, -1 y 1 respectivamente, los símbolos comodines,-2 para las palabras y 2 para las etiquetas, y el símbolo que representa a *epsilon*, que como habíamos visto es el 0. El fichero de texto correspondiente se crearía de la misma manera.

□

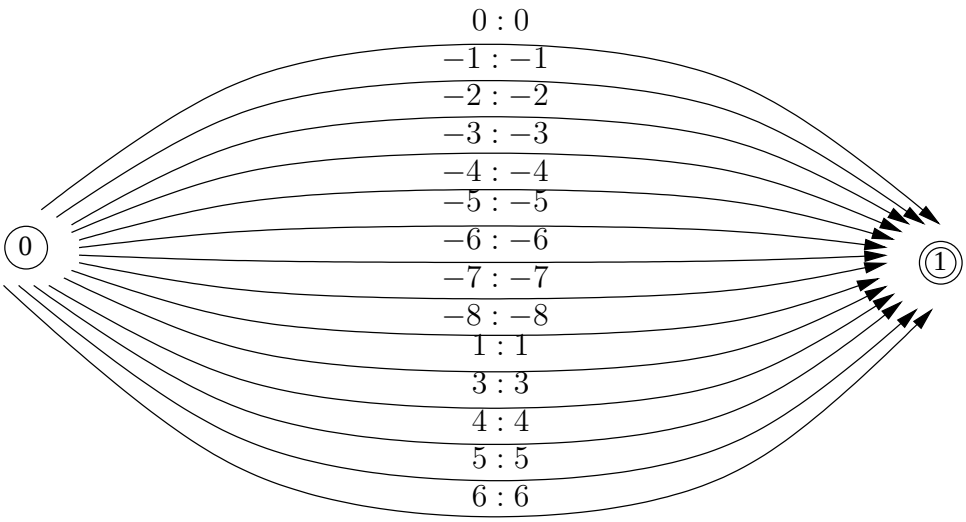

Figura 6.24: *FST* mapeado del alfabeto

6.3.2 Compilación de los traductores de estado finito

Una vez que tenemos todos los ficheros creados, tanto de traductores como del alfabeto, el siguiente paso es compilarlo todo.
Primero compilamos el alfabeto, y para ello ejecutamos el siguiente comando:

`compila` *nombreAlfabeto*`.stxt`

obteniendo como salida varios ficheros entre los que se encuentra `alfabeto.fst`, que es el traductor del alfabeto compilado.
A continuación compilamos cada uno de los traductores:

`compila` *nombreTraductor*`.stxt` *nombreTraductorCompilado*

y obtenemos como salida un fichero con extensión `.fst` que contiene el traductor original compilado y normalizado. Si a este traductor se le aplica una entrada, obtenemos como salida la misma entrada con algunos cambios, que se corresponden con la funcionalidad del traductor.

Una vez que tenemos todos los traductores compilados y con su lenguaje normalizado, ya podemos empezar a trabajar con ellos. La forma en la que podemos trabajar es con cada uno por separado, pero lo que nos interesa es construir un único traductor que involucre a todos los demás. Después de analizar las diferentes operaciones que nos ofrece la teoría de traductores llegamos a la conclusión de que la operación que buscamos es la de composición. Debemos componer todos los traductores de manera que al final obtengamos un único traductor que nos proporciona como salida, la misma que obtendríamos al aplicar todos los traductores por separado uno detrás de otro. Para esto lo que hacemos es lo siguiente:

`componer` $traductor_1$`.fst` $traductor_2$`.fst ...`

y obtenemos como salida el fichero `composicion.fst` que recoge el traductor compuesto compilado y normalizado, disponible para ser utilizado en cualquier momento.

Veamos con un ejemplo muy sencillo que realmente es la operación de composición la operación que buscamos.

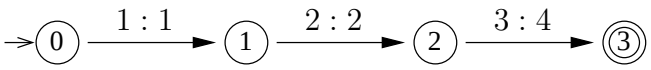

Figura 6.25: Traductor de estado finito T_1

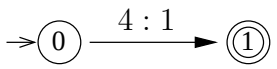

Figura 6.26: Traductor de estado finito T_2

Ejemplo 6.13 Supongamos que tenemos los traductores:

- T_1: que lo que hace es cambiar el número 3 por el número 4 si antes aparece la secuencia de números 1 y 2,
- T_2: que simplemente lo que hace es cambiar siempre el 4 por el 1.

Los traductores T_1 y T_2 se muestran en las figuras 6.25 y 6.26 respectivamente. A continuación vamos a llevar a cabo la operación de composición de ambos traductores, de manera que en primer lugar compondremos T_1 con T_2, dando como resultado el traductor $T_2 \circ T_1$ que se muestra en la figura 6.27 que lo que hace es aplicar primero el traductor T_1 y después el traductor T_2.
Veamos qué ocurre si introducimos al traductor $T_2 \circ T_1$ la entrada $1, 2, 3, 4, 5$. Obtenemos como salida la secuencia $1, 2, 1, 1, 5$ con lo cual podemos ver claramente que lo que hace el traductor es lo que realmente buscamos, aplicar primero el traductor T_1 que daría como salida $1, 2, 4, 4, 5$ para aplicar después el traductor T_2 que daría como salida $1, 2, 1, 1, 5$ que es lo que esperábamos.

La siguiente pregunta que nos podemos hacer es si la composición de T_2 con T_1 nos da o no el mismo resultado. Veámoslo a continuación siendo el traductor de estado finito de la figura 6.28 el que resulta de la composición de T_2 con T_1. Si le aplicamos la misma entrada que al caso anterior, obtendríamos como salida $1, 2, 4, 1, 5$ que como se puede ver claramente es diferente a la salida anterior. De esto deducimos que la composición es dependiente del orden, factor importante que se debe tener en cuenta a la hora de componer los traductores que representan a las reglas. □

6.3.3 Funcionamiento de los traductores de estado finito

En este momento ya estamos en condiciones de poder aplicar una entrada al traductor compuesto, de manera que a la salida obtengamos la cadena que resulta de aplicar todas las reglas por separado, con la diferencia de que aquí realizamos la operación en un único paso, con todas las ventajas que ello conlleva, tal y como vimos al principio de este tema. Para ello debemos seguir los siguientes pasos:

- Construir la entrada: para ello construimos el traductor que representa la cadena de entrada y creamos su fichero de texto correspondiente.
- Pasamos la cadena de entrada sobre el traductor compuesto:

  `traduce` *nombreEntrada*`.stxt composicion.fst` *nombreSalida*

- Obtenemos como salida un fichero de texto que contiene la entrada traducida.

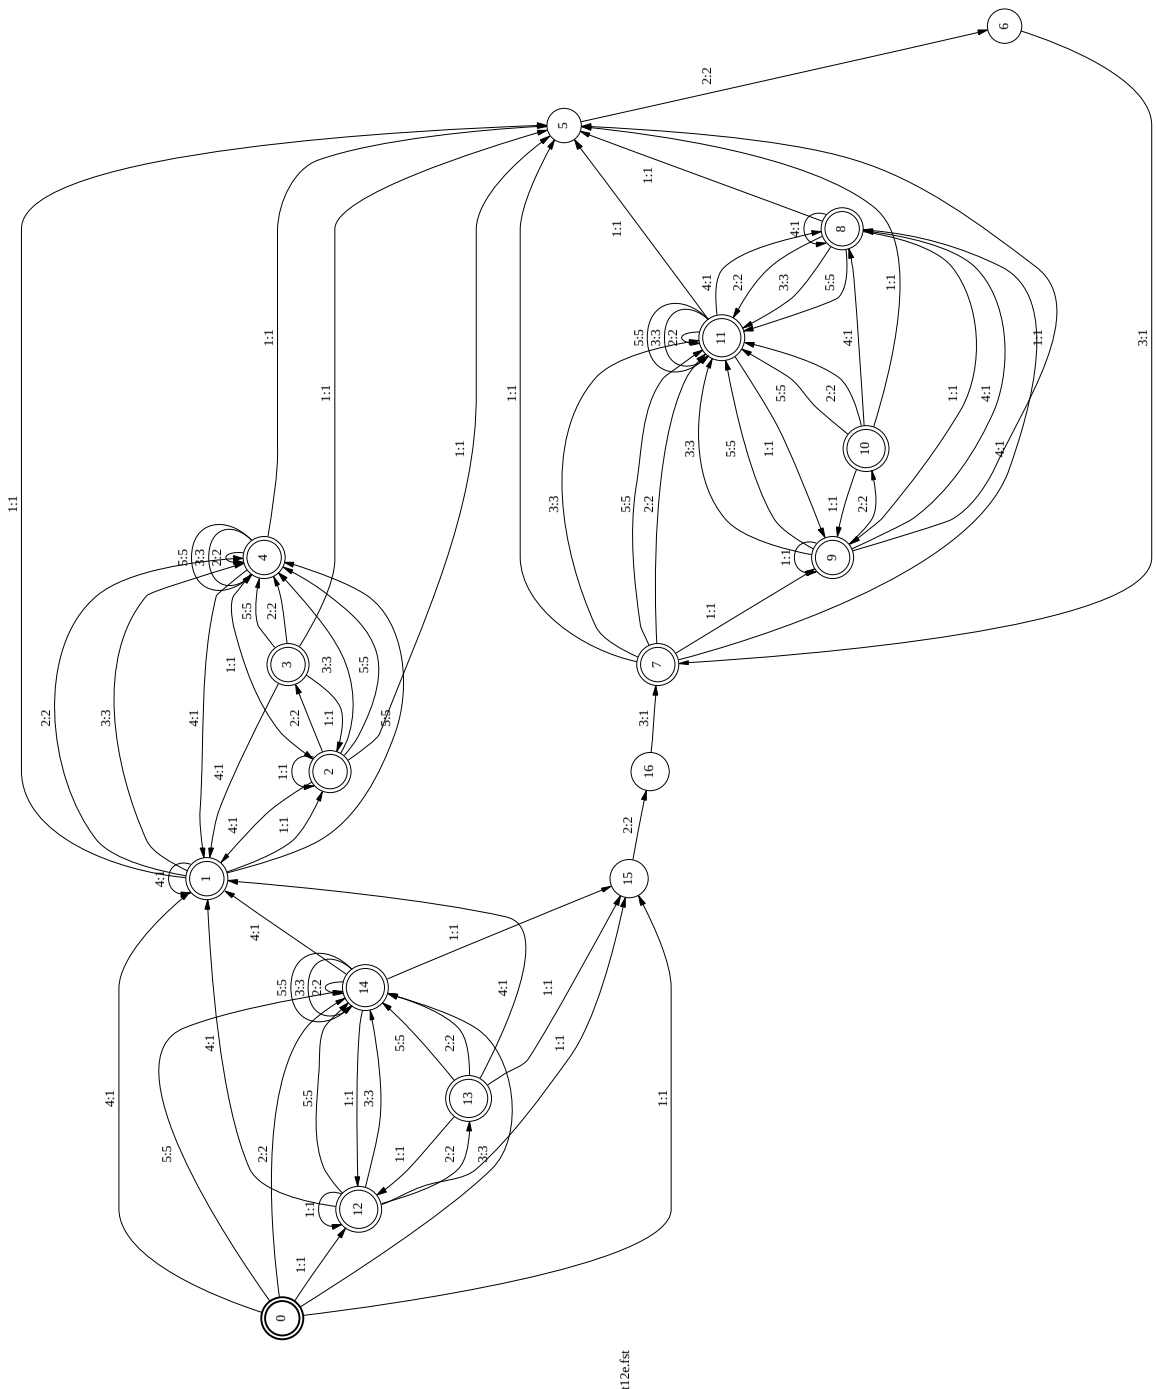

Figura 6.27: Traductor de estado finito $T_2 \circ T_1$

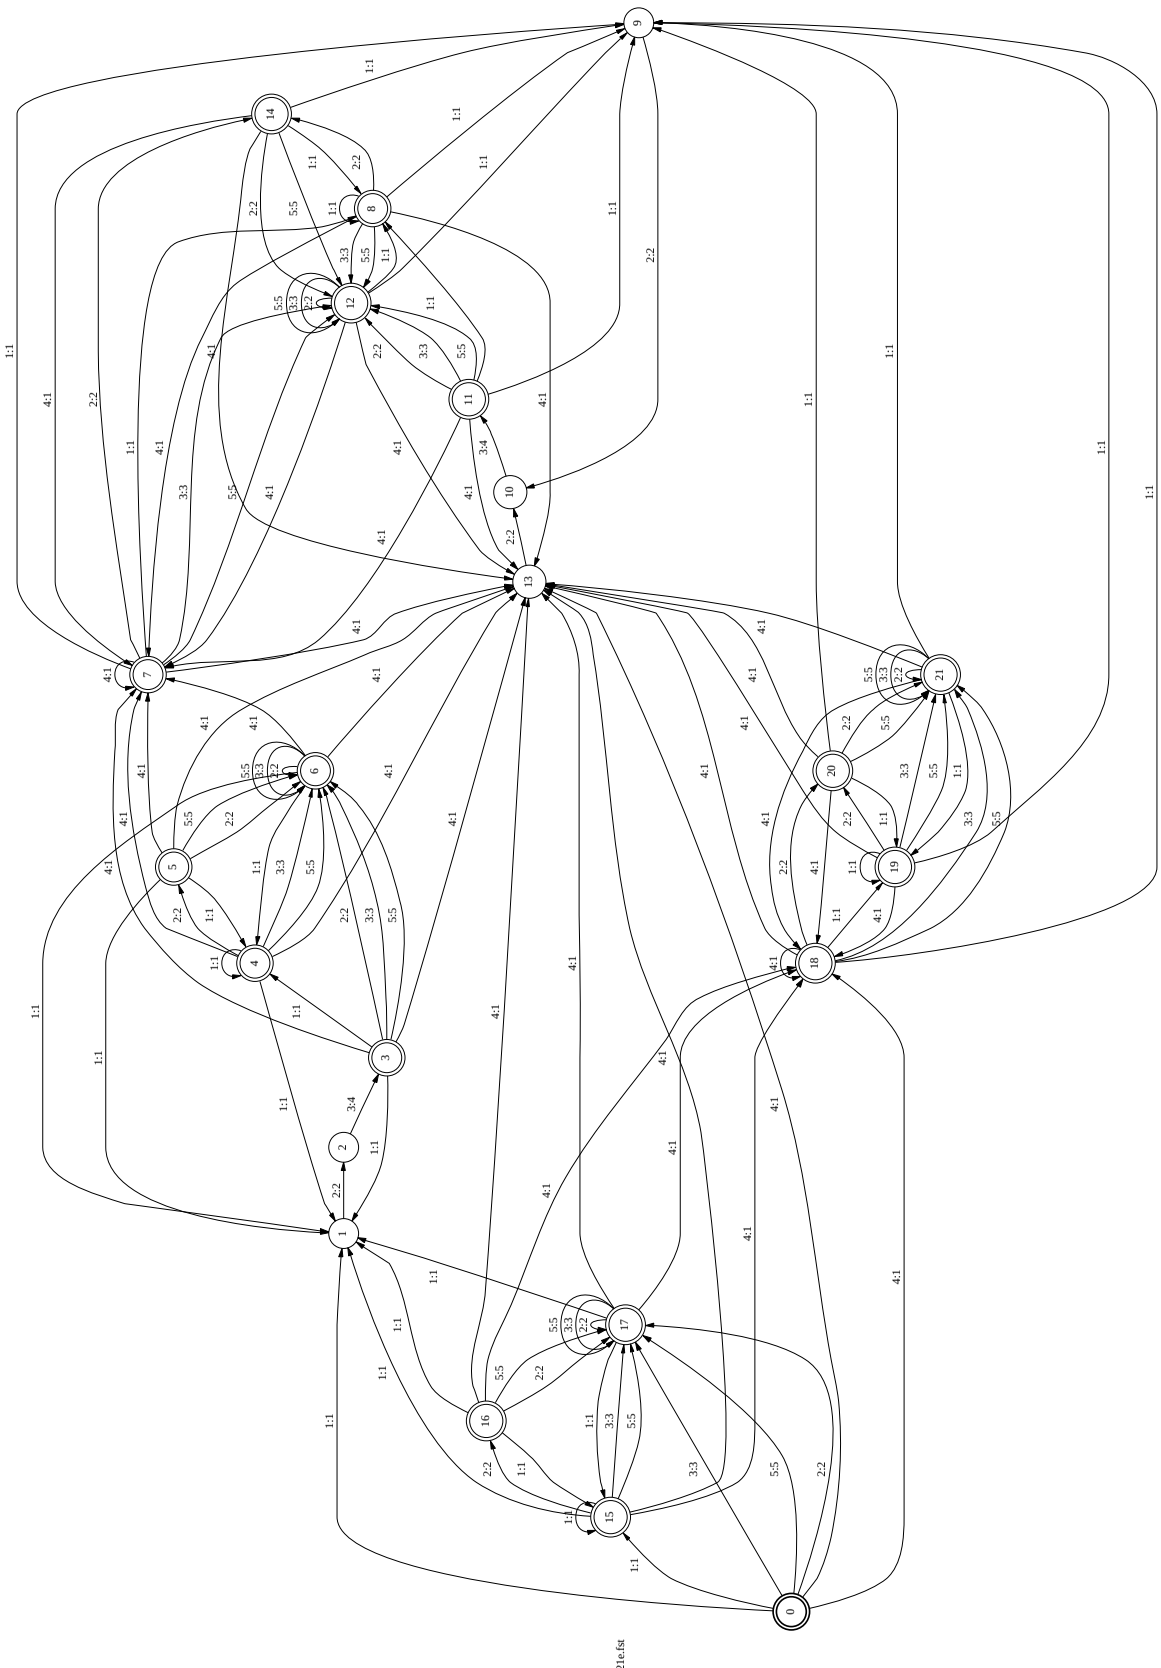

Figura 6.28: Traductor de estado finito $T_1 \circ T_2$

6.4 Trabajo de los *FST*s a bajo nivel

Para llevar a cabo la creación, la compilación y la ejecución de los traductores, comandos introducidos en el apartado anterior, nos hemos ayudado de la herramienta *FSM Library: General-purpose finite-state machine software tools* implementada por Mehryar Mohri, Fernando C. N. Pereira y Michael D. Riley de los laboratorios *AT&T* [Mohri 1995, Mohri 1997]. Básicamente lo que aporta esta librería son un conjunto de operaciones sobre autómatas y traductores, que nosotros hemos aprovechado con la intención de conseguir nuestros objetivos. De esta manera los comandos introducidos en el apartado anterior son una serie de *scripts* que llaman a operaciones de esta librería.
Veamos cada uno de estos comandos por separado y de forma más detallada, para estudiar lo que realmente hacen a bajo nivel:

- **Compilación:**
  Este comando lo que hace es, en primer lugar, convertir el fichero de texto en la estructura de datos interna utilizada por la librería para poder llevar a cabo las operaciones pertinentes. Para ello se ejecuta el comando:

  `fsmcompile -i`*nombreAlfabeto*`.syms -o`*nombreAlfabeto*`.syms`
  `-t <`*nombreTraductor*`.stxt>` *nombreTraductorCompilado*`.fst`

  A continuación, lo que hace es normalizar el lenguaje del traductor siguiendo los siguientes pasos:
  Supongamos que T sea el traductor sobre el que queremos operar y Σ el alfabeto con el que vamos a trabajar, ambos ficheros con extensión `.fst`, entonces:

  Paso 1) $a = p_1(T)$
  Paso 2) $\Gamma = \Sigma^* - \Sigma^* a \Sigma^*$
  Paso 3) $N = \Gamma(T\Gamma)^*$

  Desglosemos un poco más en qué consiste cada uno de estos pasos:

  - Paso 1: Simplemente hacemos la primera proyección del traductor T con el propósito de quedarnos con los símbolos de entrada de dicho traductor.
    Para ello utilizamos la operación:

    `fsmproject -i T.fst > a.fst`

  - Paso 2: Este paso lleva implícito distintas operaciones:
    - *Kleene star* del alfabeto, para permitir que aparezca más de un símbolo:

      `fsmclosure` Σ`.fst >` Σ^*`.fst`
    - Concatenación de Σ^* con a:

      `fsmconcat` Σ^*`.fst a.fst` Σ^*`.fst >` $\Sigma^* a \Sigma^*$`.fst`
    - Diferencia de Σ^* y $\Sigma^* a \Sigma^*$: esta operación únicamente puede llevarse a cabo con autómatas, y nosotros trabajamos con traductores, con lo cual para poder llevarla a cabo primero debemos hacer la primera proyección de ambos sustraendos:

      `fsmproject -i` Σ^*`.fst >` $p_1(\Sigma^*)$`.fsa`[5]
      `fsmproject -i` $\Sigma^* a \Sigma^*$`.fst >` $p_1(\Sigma^* a \Sigma^*)$`.fsa`
      `fsmdifference` $p_1(\Sigma^*)$`.fsa` $p_1(\Sigma^* a \Sigma^*)$`.fsa >` Γ`.fsa`

  - Paso 3: Este paso también lleva varias operaciones implícitas, que veremos a continuación:

[5] Extensión que se le da a los ficheros de texto que representan autómatas.

* Concatenación del traductor T con Γ:
  `fsmconcat T.fst Γ.fsa > TΓ.fst`
* *Kleene star* de la concatenación anterior:
  `fsmclosure T Γ.fst > (TΓ)*.fst`
* Concatenación de Γ con el cierre hecho en el paso anterior:
  `fsmconcat Γ.fsa (TΓ)*.fst > N.fst`

Una vez realizados todos estos pasos el traductor de estado finito resultante, compilado y normalizado, está ya en condiciones de operar.

- **Concatenación:**
  Este es el siguiente comando a utilizar una vez compilado todo, y no hace otra cosa más que la operación de composición, cuya definición formal ha sido introducida en el primer apartado del tema. Únicamente debemos destacar de nuevo que esta operación es dependiente del orden, lo que hay que tener en cuenta antes de llevarla a cabo, para obtener como salida lo que realmente queremos:

  `fsmcompose` *traductor*$_1$`.fst` *traductor*$_2$`.fst ... > composicion.fst`

- **Traducción:**
  Este es el comando que pone en funcionamiento al traductor. A partir de una entrada nos devuelve una salida con los cambios que vienen determinados por la operación del traductor. Para ello utilizamos la operación de composición, de manera que si la cadena de entrada pertenece al lenguaje del traductor, obtenemos como salida un traductor con la cadena de entrada como símbolos de entrada y con la cadena de salida como símbolos de salida. Para quedarnos únicamente con la cadena de salida hacemos la segunda proyección sobre el traductor obteniendo así el autómata correspondiente que representa a la cadena de salida. Si la cadena de entrada no pertenece al lenguaje del traductor, la salida es vacía. También debemos recordar que la cadena de entrada debe transformarse en un traductor en el que no se produce ninguna traducción, sino que la entrada se mantiene a la salida. Indicar que antes de nada lo que se hace es compilar el traductor que representa a la cadena de entrada.

  `fsmcompile -i`*nombreAlfabeto*`.syms -o`*nombreAlfabeto*`.syms -t`
  nombreEntrada`.stxt > `*nombreEntrada*`.fst`
  `fsmcompose` *entrada*`.fst composicion.fst > `*salida*`.fst`
  `fsmproject -o` *salida*`.fst >` p_2(*salida*)`.fsa`
  `fsmrmepsilon` *salida*`.fst >` p_2(*salida*) $-$ *sin* $-$ ϵ`.fsa`
  `fsmprint -i`*nombreAlfabeto*`.syms -o`*nombreAlfabeto*`.syms`
  p_2(*salida*) $-$ *sin* $-$ ϵ`.fsat >` *salida*`.stxt`

6.5 Un ejemplo completo

A continuación, con el propósito de verificar el funcionamiento de todo lo indicado en los apartados anteriores, nos disponemos a mostrar un ejemplo de ejecución completo y detallado paso a paso. Se trata de un prototipo que nos va a mostrar que realmente todas las ideas que hemos desarrollado se pueden aplicar en la práctica[6].

[6] En el CD que se adjunta se proporciona todo lo necesario para poner en práctica dicho ejemplo.

En primer lugar sería labor de los lingüistas crear un conjunto de reglas en función de los esquemas generales de reglas que hemos indicado. Para llevar a cabo el ejemplo supongamos que nos han proporcionado este pequeño conjunto de reglas:

1. `SELECCIONA (S) (1 ES {V});`
   Esta regla nos dice que la etiqueta de la palabra actual será un *sustantivo* si la palabra que le sigue es un *verbo*.

2. `BORRA (V) (-2 CONTIENE {P,V});`
   Esta regla dice que si la segunda palabra anterior a la actual tiene entre sus etiquetas posibles a una *preposición* y a un *verbo*, entonces la palabra actual no podrá ser *verbo*.

3. `SELECCIONA (P) (-2 PERTENECE {bajo,sobre}, -1 ES {V});`
   Esta regla nos dice que la palabra actual será una *preposición* si la palabra anterior es un *verbo* y la segunda palabra anterior es `bajo` o `sobre`.

4. `FUERZA (D) (1 PERTENECE sobre, NOT 1 ES {P});`
   Esta regla dice que la palabra actual será forzosamente un *determinante* si la siguiente palabra es `sobre` y no es una *preposición*.

Una vez que tenemos las reglas el siguiente paso sería crear el mini-diccionario y el mini-tag-set que recogen todas las palabras y las etiquetas involucradas en las reglas. Recordamos que tanto el mini-diccionario como el mini-tag-set también recogen los *mapping* de cada una de las palabras con números negativos y de cada una de las etiquetas con números positivos, reservando el -1 y el 1 para inicio y fin de frase respectivamente, además del -2 y 2 como comodín de palabras y etiquetas respectivamente. De esta manera nuestro mini-diccionario y nuestro mini-tag-set sería el siguiente:

Mini-diccionario		**Mini-tag-set**	
bajo	-3	D	3
sobre	-4	P	4
		S	5
		V	6

A continuación tenemos que construir los traductores de estado finito que representan a las reglas. Veamos entonces cuál es el traductor que se corresponde con cada una de las reglas anteriores:

1. `SELECCIONA (S) (1 ES {V});`
   Para esta primera regla, el traductor de estado finito resultante se muestra en la figura 6.29 y de él destacamos que nos quedamos con la etiqueta a seleccionar dejando las demás a *epsilon* si la palabra que aparece a continuación tiene únicamente a *verbo* como posible etiqueta. El traductor que resulta de hacer el *mapping* es el que se muestra en la figura 6.30, y su fichero de texto correspondiente es el que se indica a continuación:

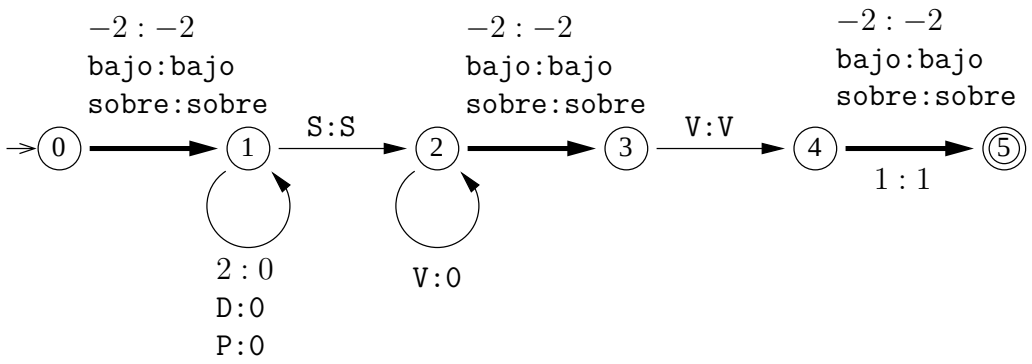

Figura 6.29: *FST* para la regla: `SELECCIONA (S) (1 ES {V});`

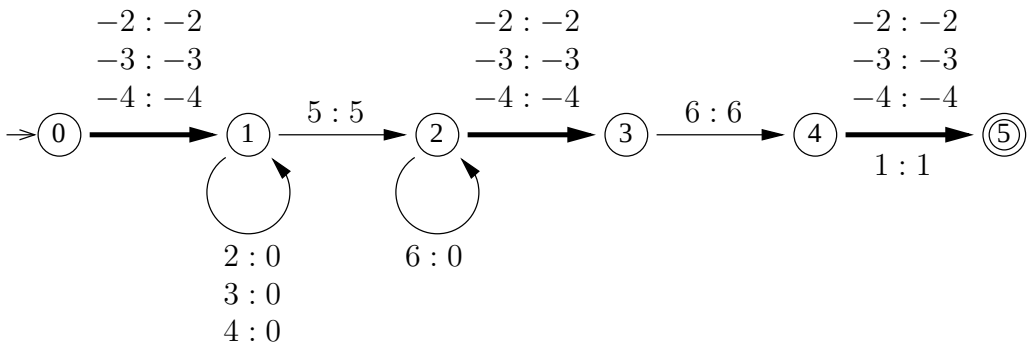

Figura 6.30: *FST* mapeado para la regla: `SELECCIONA (S) (1 ES {V});`

Estado origen	Estado destino	Símbolo entrada	Símbolo salida
0	1	−2	−2
0	1	−3	−3
0	1	−4	−4
1	1	2	0
1	1	3	0
1	1	4	0
1	2	5	5
2	2	6	0
2	3	−2	−2
2	3	−3	−3
2	3	−4	−4
3	4	6	6
4	5	−2	−2
4	5	−3	−3
4	5	−4	−4
4	5	1	1
5			

2. `BORRA (V) (-2 CONTIENE {P,V});`
   Para la segunda regla, los traductores de estado finito sin y con *mapping* son los que se muestran en las figuras 6.31 y 6.32 respectivamente, y de estos traductores destacamos que la etiqueta `V` de la palabra actual la transformamos en *epsilon* si la segunda palabra anterior contiene a las etiquetas `P` y `V`, y por lo menos contiene también una etiqueta más.

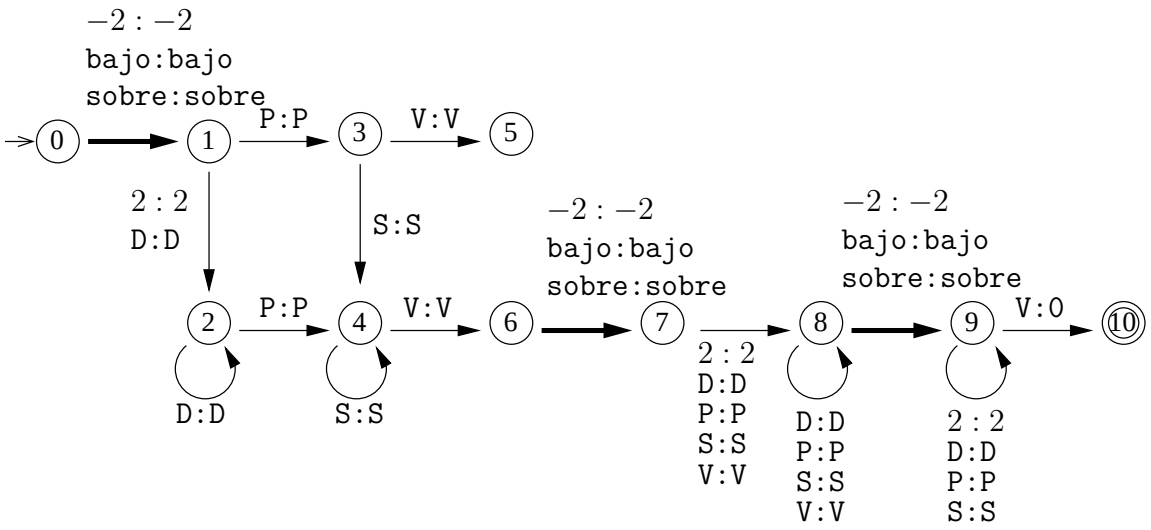

Figura 6.31: *FST* para la regla: `BORRA (V) (-2 CONTIENE {P,V});`

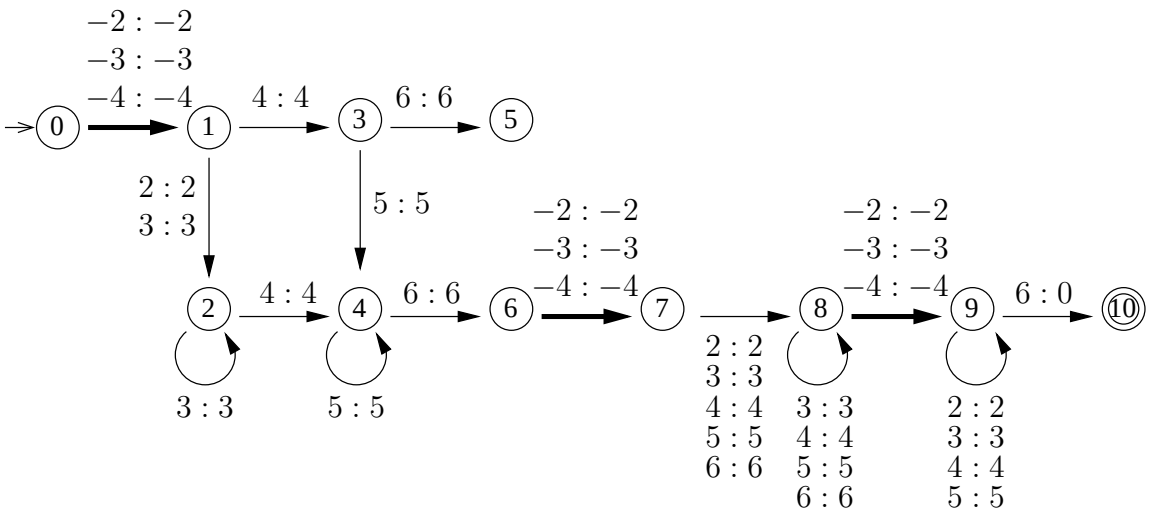

Figura 6.32: *FST* mapeado para la regla: `BORRA (V) (-2 CONTIENE {P,V});`

El fichero de texto se construiría de la misma forma que en el caso anterior.

3. `SELECCIONA (P) (-2 PERTENECE {bajo,sobre}, -1 ES {V});`
   Para la tercera regla, el traductor de estado finito que la representa es el de la figura 6.33, y de este traductor destacamos que de la palabra actual seleccionamos *preposición* dejando el resto de etiquetas a *epsilon* si la palabra anterior es exactamente *verbo* y la segunda palabra anterior es o bien `bajo`, o bien `sobre`. El traductor que resulta de hacer el *mapping* es el que se muestra en la figura 6.34. El fichero de texto se construiría de la misma forma que para la primera regla.

4. `FUERZA (D) (1 PERTENECE sobre, NOT 1 ES {P});`
   Y para la cuarta y última regla, los traductores son los mostrados en las figuras 6.35 y 6.36. De estos traductores destacamos que de *epsilon* traducimos a *determinante* dejando el resto de etiquetas a *epsilon*, ya que hablamos de un `FUERZA`, si la siguiente palabra es `sobre` y no tiene exactamente como etiqueta *preposición*. El fichero de texto se construiría de la misma forma que para la primera regla.

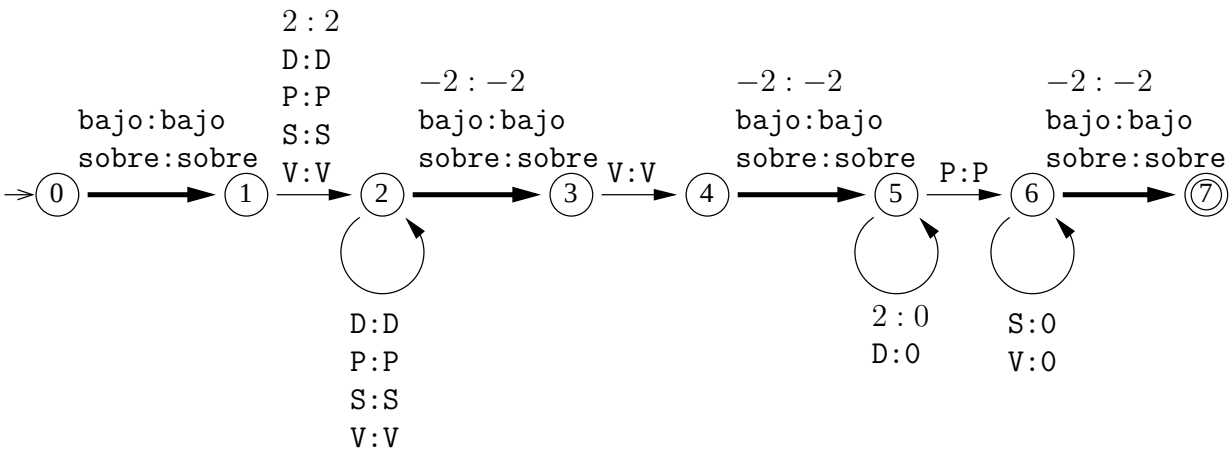

Figura 6.33: *FST* para la regla: `SELECCIONA (P) (-2 PERTENECE {bajo,sobre}, -1 ES {V});`

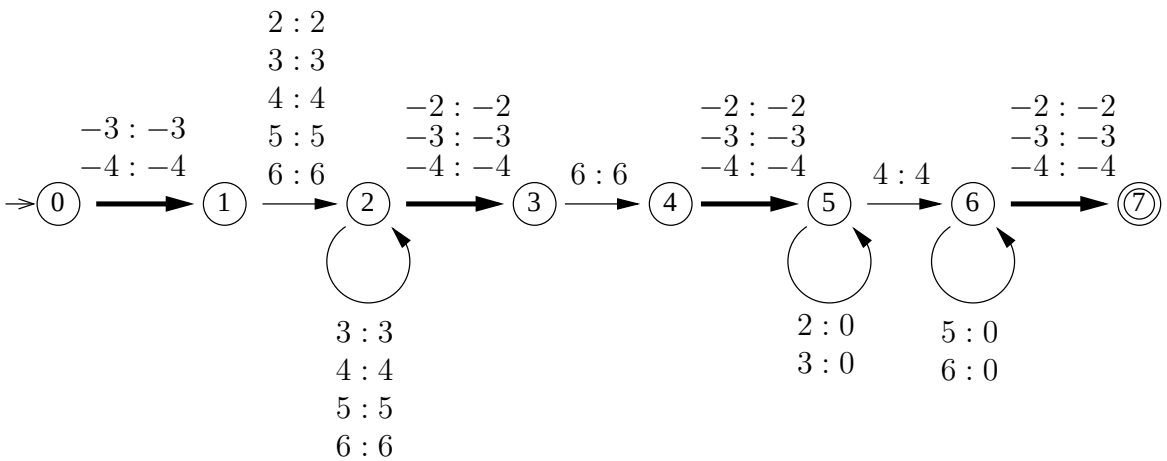

Figura 6.34: *FST* mapeado para la regla: `SELECCIONA (P) (-2 PERTENECE {bajo,sobre}, -1 ES {V});`

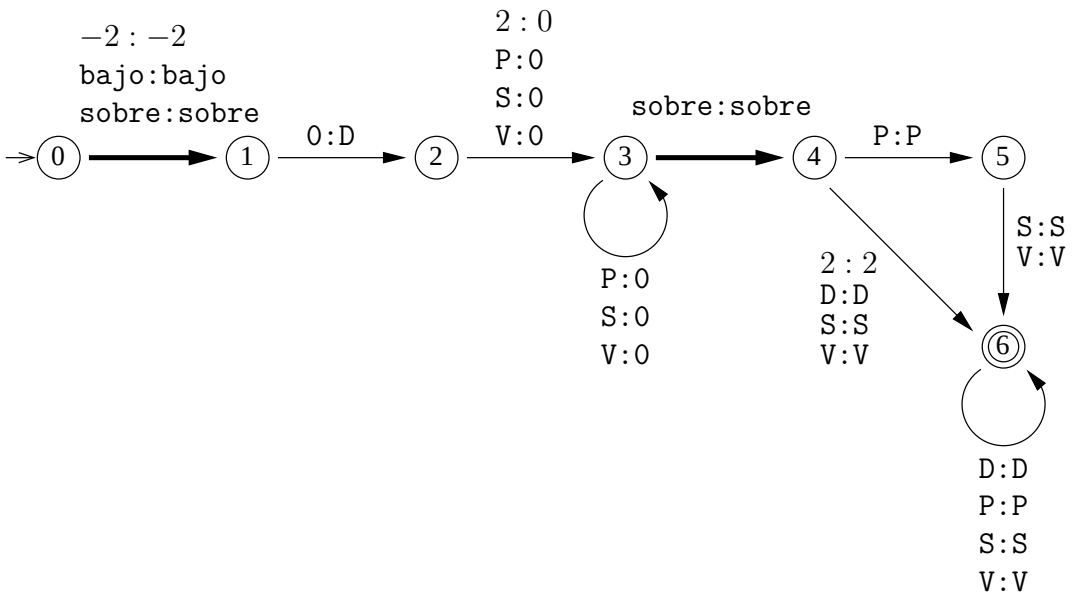

Figura 6.35: *FST* para la regla: `FUERZA (D) (1 PERTENECE sobre, NOT 1 ES {P});`

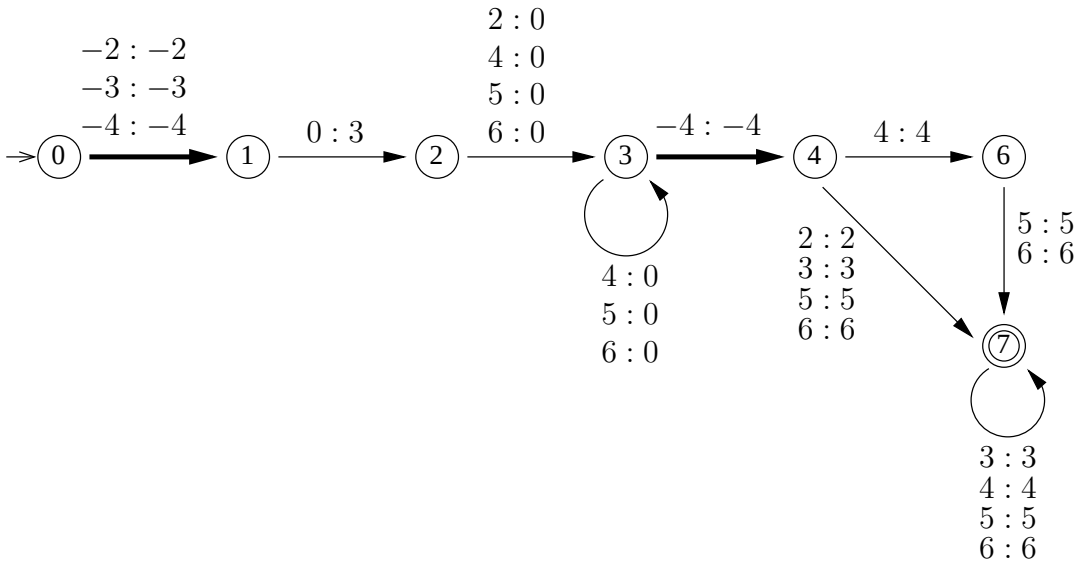

Figura 6.36: *FST* mapeado para la regla: `FUERZA (D) (1 PERTENECE {sobre}, NOT 1 ES {P});`

Una vez que ya tenemos los ficheros de texto de los traductores y el fichero de símbolos del alfabeto, que estará formado por las palabras del mini-diccionario y por las etiquetas del mini-tag-set, además de los símbolos para *epsilon*, comodines e inicio y fin de frase, se procede a la compilación de cada uno de los traductores en cuestión. Después se combinan todos, y ya estamos en condiciones de poder aplicar una entrada al traductor compuesto. Para este ejemplo, la forma de actuar sería la siguiente:

1. Compilación del alfabeto:

```
compilaAlfabeto alfabeto.stxt
```

2. Compilación de los traductores de las reglas:

```
compila regla1.stxt n1

compila regla2.stxt n2

compila regla3.stxt n3

compila regla4.stxt n4
```

3. Composición de los traductores compilados y normalizados:

```
componer n1.fst n2.fst n3.fst n4.fst
```

4. Y ejecución del traductor compilado

```
traduce entrada.stxt composicion.fst salida
```

Para la ejecución del traductor compuesto necesitamos una entrada, y para nuestro ejemplo hemos elegido la siguiente:

El	sobre	está	sobre	la	mesa
Pron	P	V	P	D	S
	S		S	Pron	V
	V		V		

Utilizando el mapeo, la entrada es:

-2	-4	-2	-4	-2	-2
2	4	6	4	2	5
	5		5	3	6
	6		6		

Para poder aplicar la entrada al sistema es necesario crear el traductor de estado finito que representa este enrejado, y este traductor es el que se muestra en la figura 6.37.

Al aplicar la entrada al traductor, como salida obtenemos el traductor que se muestra en la figura 6.38, y sus enrejados, mapeado y sin mapear, correspondientes son los que se indican a continuación:

-2	-4	-2	-4	-2	-2
3	5	6	4	2	5
				3	

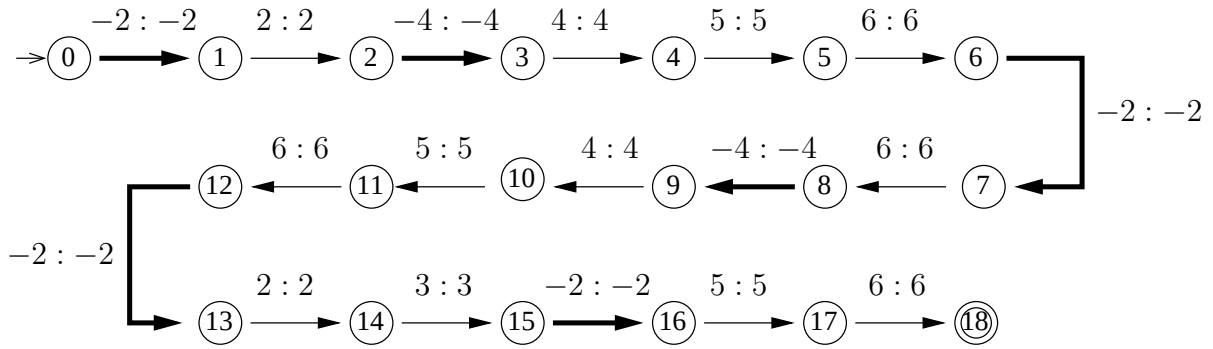

Figura 6.37: *FST* de la entrada

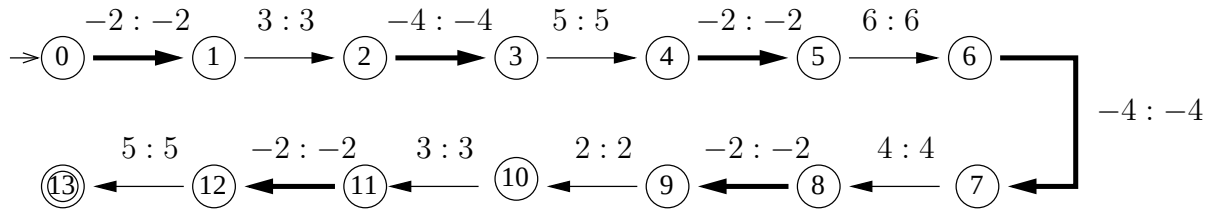

Figura 6.38: *FST* de la salida

El	sobre	está	sobre	la	mesa
D	S	V	P	D	S
				Pron	

Como podemos ver, el traductor ha llevado a cabo algunos cambios sobre la entrada, pero nos podemos preguntar si estos cambios son realmente los buenos. Para poder corroborar que sí lo son, veamos cómo afecta cada una de las reglas a la entrada:

Enrejado inicial.	El	sobre	está	sobre	la	mesa
	Pron	P	V	P	D	S
		S		S	Pron	V
		V		V		
Primera regla encajada y ejecutada.	El	sobre	está	sobre	la	mesa
	Pron	S	V	P	D	S
				S	Pron	V
				V		
Segunda regla encajada y ejecutada.	El	sobre	está	sobre	la	mesa
	Pron	S	V	P	D	S
				S	Pron	
				V		
Tercera regla encajada y ejecutada.	El	sobre	está	sobre	la	mesa
	Pron	S	V	P	D	S
					Pron	

Cuarta regla encajada y ejecutada.	El	sobre	está	sobre	la	mesa
	D	S	V	P	D	S
					Pron	

Efectivamente, vemos que la ejecución del traductor resultante de componer todas las reglas contextuales produce la misma salida que la ejecución individual de cada regla por separado. Por tanto, a través de este caso de estudio, hemos ilustrado de manera práctica las ventajas de la compilación de reglas contextuales en estructuras más eficientes como son los *FST*,s. La única desventaja que hemos podido detectar ha sido quizás que el tamaño de los traductores compilados y normalizados no es tan compacto como cabría esperar en un principio. Esto puede deberse a la propia naturaleza de los traductores, o al coste estructural de la operación de composición, al menos en esta herramienta. El capítulo de conclusiones finales incluye algunas reflexiones más detalladas sobre todos estos aspectos.

Parte IV

Formalización del proceso de segmentación

Capítulo 7

Extensiones del algoritmo de Viterbi

Los diferentes tipos de etiquetadores que existen actualmente asumen que el texto de entrada aparece ya correctamente segmentado, es decir, dividido de manera adecuada en *tokens* o unidades de información de alto nivel de significado, que identifican perfectamente cada uno de los componentes de dicho texto. Esta hipótesis de trabajo no es en absoluto realista debido a la naturaleza heterogénea tanto de los textos de aplicación como de las fuentes donde se originan.

Así pues, algunas lenguas, como el gallego [Alvarez, Regueira y Montegudo 1986] o el español, presentan fenómenos que es necesario tratar antes de realizar la etiquetación. Entre otras tareas, el proceso de segmentación se encarga de identificar unidades de información tales como las frases o las propias palabras. Esta operación puede ser más compleja de lo que parece *a priori*. Por ejemplo, la identificación de las frases se suele realizar considerando ciertas marcas de puntuación. Sin embargo, un simple punto puede ser indicativo de fin de frase, pero podría corresponder también al carácter final de una abreviatura.

En el caso de las palabras, la problemática se centra en que el concepto ortográfico de palabra no siempre coincide con el concepto lingüístico. Se presentan entonces dos opciones:

1. Las aproximaciones más sencillas consideran igualmente las palabras ortográficas y amplían las etiquetas para representar aquellos fenómenos que sean relevantes. Por ejemplo, la palabra `reconocerse` podría etiquetarse como `V000f0PE1`[1] aun cuando está formada por un verbo y un pronombre enclítico, y las palabras de la locución preposicional `a pesar de` se etiquetarían respectivamente como `P31`, `P32` y `P33` aun cuando constituyen un único término. Sin embargo, en idiomas como el gallego, este planteamiento no es viable, ya que su gran complejidad morfológica produciría un crecimiento excesivo del juego de etiquetas. Esto complica, entre otras cosas, la creación de los recursos lingüísticos, como por ejemplo textos etiquetados, que son necesarios para ajustar los parámetros de funcionamiento de los etiquetadores.

2. La solución pasa entonces por no ampliar el juego de etiquetas básico. Como ventajas, la complejidad del proceso de etiquetación no se verá afectada por un número elevado de etiquetas, la creación de recursos lingüísticos será más sencilla y la información relativa a cada término lingüístico se puede expresar de manera más precisa. Por ejemplo, a lo que antes era un simple pronombre enclítico se le pueden atribuir ahora valores de persona, número, caso, etc. Como desventaja, se complican las labores del preprocesador, que no sólo se verá obligado a identificar las palabras ortográficas, sino que unas veces tendrá que partir una palabra en varias, y otras veces tendrá que juntar varias palabras en una sola.

[1] Las etiquetas que aparecen en este capítulo pertenecen a los *tag sets* utilizados en los proyectos Galena (Generador de Analizadores para LEnguajes NAturales) y Corga (COrpus de Referencia do Galego Actual), y su descripción se detalla en el apéndice A.

Las mayores dificultades surgen cuando esta segmentación es ambigua. Por ejemplo, la expresión `sin embargo` se etiquetará normalmente de manera conjunta como una conjunción, pero en algún otro contexto podría ser una secuencia formada por una preposición y un sustantivo. De igual forma, la palabra `ténselo` puede ser una forma del verbo `tener` con dos pronombres enclíticos, o bien una forma del verbo `tensar` con un solo pronombre. Este fenómeno es muy común en gallego, no sólo con los pronombres enclíticos, sino también con algunas contracciones. Por ejemplo, la palabra `polo` puede ser un sustantivo (en español, pollo), o bien la contracción de la preposición `por` (por) y del artículo `o` (el), o incluso la forma verbal `pos` (pones) con el pronombre enclítico `o` (lo).

En este trabajo hemos adoptado la segunda opción, es decir, la de separar y unir (separar, por ejemplo, el verbo de sus pronombres, y unir, por ejemplo, los diferentes constituyentes de una locución). En cualquier caso, la primera opción, la de trabajar al nivel de la palabra ortográfica, necesitaría, después de la fase de etiquetación, una fase de post-procesamiento, cuando se desee identificar los diferentes componentes sintácticos del texto. Dicha fase de post-procesamiento realizaría las labores análogas a las que involucra nuestro preprocesador.

Para dar una idea de la complejidad de los problemas que se afrontan, vamos a poner algunos casos típicos que es capaz de resolver el preprocesador:

Ejemplo 7.1 Supongamos que tenemos la expresión `polo tanto` (por lo tanto o por el tanto). En este caso, estamos ante una locución insegura, es decir, `polo tanto` puede ser una locución, `polo` a su vez puede ser un sustantivo, una contracción o un verbo con pronombres enclíticos, y `tanto`, por su parte, puede ser sustantivo o adverbio, si no forma parte de la locución. La representación sería la siguiente[2]:

```
<alternativa>
<alternativa1>
polo [Scms polo]
tanto
</alternativa1>
<alternativa2>
por  [P por]
+o   [Ddms o]
tanto
</alternativa2>
<alternativa3>
po   [Vpi2s0 pór] [Vpi2s0 poñer]
+o   [Raa3ms o]
tanto
</alternativa3>
<alternativa4>
por&+o&tanto
</alternativa4>
</alternativa>
```

Un ejemplo de aplicación de las 4 diferentes acepciones sería:

- **Sustantivo+Adverbio**: `Coméche-lo polo tanto, que non quedaron nin os osos` (comiste el pollo tanto, que no quedaron ni los huesos).

[2]Esta es la salida que nos da el preprocesador y refleja todas las segmentaciones posibles con las que nos podemos encontrar.

- **Preposición+Artículo+Sustantivo**: `Gañaron o partido polo tanto da estrela` (ganaron el partido por el tanto de la estrella).
- **Verbo+Pronombre+Adverbio**: `Pois agora polo tanto ti coma el` (pues ahora lo pones tanto tú como él).
- **Locución**: `Estou enfermo, polo tanto quédome na casa` (estoy enfermo, por lo tanto me quedo en casa).

□

Ejemplo 7.2 Un ejemplo de conflicto entre dos posibles descomposiciones de enclíticos aplicable al español sería `ténselo`, que puede ser `tense` (de tensar) más `lo` ó `ten` (de tener) más `se` más `lo`, por lo que la representación correspondiente es:

```
<alternativa>
<alternativa1>
ténse [V2spm0 tensar]
+lo    [Re3sam el]
</alternativa1>
<alternativa2>
tén   [V2spm0 tener]
+se    [Re3yyy se]
+lo    [Re3sam el]
</alternativa2>
</alternativa>
```

□

7.1 El nuevo etiquetador

Una vez que tengamos la salida del preprocesador, y debido a las segmentaciones ambiguas que hemos descrito anteriormente, el etiquetador debe ser capaz de enfrentarse a flujos de *tokens* de distinta longitud. Es decir, no sólo debe ser capaz de decidir qué etiqueta asignar a cada *token*, sino que además debe saber decidir si algunos de ellos constituyen o no una misma entidad y asignar, en cada caso, la cantidad de etiquetas adecuada, en función de las alternativas de segmentación que le proporciona el preprocesador.

Para llevar a cabo este proceso, se podría considerar la construcción de etiquetadores especializados para todas las posibles alternativas, la posterior comparación de sus correspondientes salidas, y la selección de la más plausible. No obstante, esta posibilidad plantea varios inconvenientes. En primer lugar, sería necesario definir algún criterio objetivo de comparación. Si el paradigma de etiquetación que se está utilizando es, por ejemplo, el de los modelos de Markov [Brants 2000] ocultos, como es nuestro caso, dicho criterio podría ser la comparación de las probabilidades acumuladas normalizadas. Por ejemplo, en la figura 7.1, llamemos p_i a la probabilidad acumulada del mejor camino (marcado con una línea más gruesa) del enrejado i. Estos valores, es decir p_1, p_2, p_3 y p_4, no son directamente comparables. No obstante, si utilizamos probabilidades logarítmicas podemos obtener valores normalizados dividiendo dichas probabilidades por el número de *tokens*. En este caso, $p_1/5$, $p_2/6$, $p_3/7$ y $p_4/7$ sí que son comparables. En otros paradigmas, los criterios podrían no ser tan sencillos de identificar, y, en cualquier caso, la evaluación individual de cada posible combinación de las diferentes alternativas conllevaría un coste computacional bastante elevado. Por ejemplo, si otra

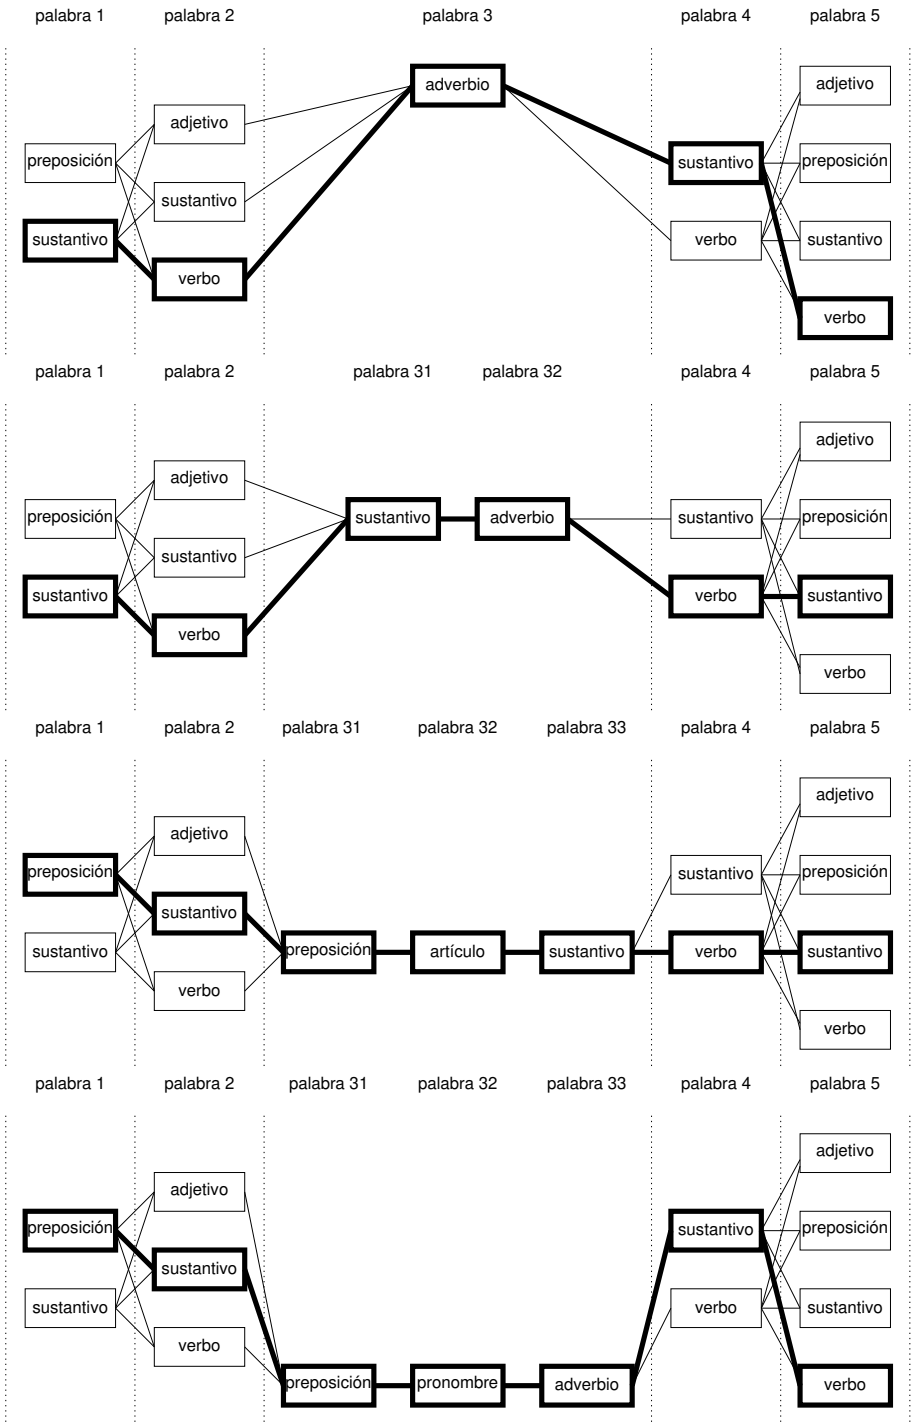

Figura 7.1: Conjunto de diferentes segmentaciones sobre distintos enrejados

palabra con dos segmentaciones posibles apareciera en la misma frase de la figura 7.1, entonces tendríamos $4 \times 2 = 8$ secuencias de *tokens* diferentes.

Por ello, en nuestro caso, hemos preferido abordar el diseño de una extensión del algoritmo de Viterbi [Viterbi 1967] que, sin pérdida de generalidad y sin necesidad de información extra, es capaz de etiquetar flujos de *tokens* de distinta longitud sobre el mismo enrejado (ver figura 7.2), y además con una complejidad temporal comparable al del algoritmo de Viterbi clásico. Este

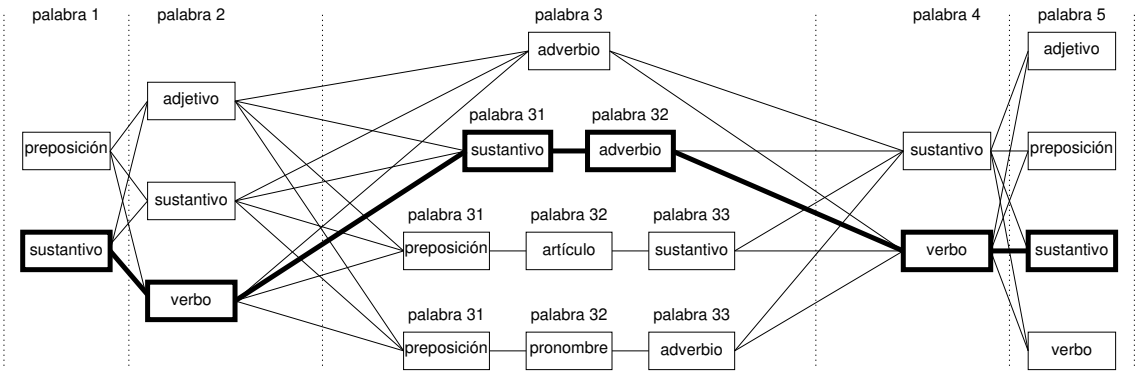

Figura 7.2: Conjunto de diferentes segmentaciones sobre el mismo enrejado

es, por tanto, el paso final del proceso, y su salida es precisamente el texto segmentado y desambiguado.

7.2 Extensiones del algoritmo de Viterbi

Como indicamos anteriormente vamos a adaptar el algoritmo de Viterbi para que sea capaz de enfrentarse a flujos de *tokens* de distinta longitud. Es decir, a parte de asignar una etiqueta a cada *token*, debe ser capaz de decidir si alguno de ellos constituye o no una misma entidad y asignar, en cada caso, la cantidad de etiquetas adecuada en función de las diferentes alternativas de segmentación.

7.2.1 Representación de las alternativas de segmentación sobre un *retículo*

Para poder llevar a cabo la modificación del algoritmo de Viterbi, en primer lugar debemos definir una estructura capaz de representar coherentemente las distintas alternativas de segmentación que nos proporciona el módulo de procesamiento de una frase. Lo primero que nos podemos preguntar es si nos sirven los enrejados clásicos. Para ello veamos un ejemplo y estudiemos sobre él dicha posibilidad.

Ejemplo 7.3 Supongamos que tenemos la frase: `El sin embargo fue`. El preprocesador nos da dos segmentaciones posibles para `sin embargo`: una que se corresponde con un *token*, en cuyo caso hablaremos de *conjunción*, y otra que se corresponde con dos *tokens*, en cuyo caso hablaremos de *preposición* y *sustantivo*.

Si a continuación empezamos a construir el enrejado de Viterbi, tal y como se muestra en el primer enrejado de la figura 7.3, llegamos a un punto donde no sabemos dónde colocar la etiqueta *conjunción* que etiqueta a `sin embargo` como única entidad. Podríamos colocarla debajo de la palabra `sin` o debajo de la palabra `embargo`, supongamos que la colocamos debajo de la primera palabra, tal y como se muestra en el segundo enrejado de la figura. En este punto nos vamos a encontrar con otro inconveniente, y es que no se puede establecer un enlace entre la etiqueta `C` y la etiqueta `S` de la palabra `embargo`, tal y como se ilustra en el tercer enrejado de la figura. Para solucionar este inconveniente pensamos en establecer unas marcas de principio y fin de *token*. De esta manera llegamos a construir el enrejado de forma correcta, tal y como se muestra al final de la figura 7.3. No obstante, como vimos, el enrejado clásico presenta muchas trabas a la hora de representar las segmentaciones ambiguas que nos proporciona el módulo del preprocesador. Por este motivo, decidimos que es adecuado pensar en otra estructura más coherente y cómoda que nos facilite la representación. □

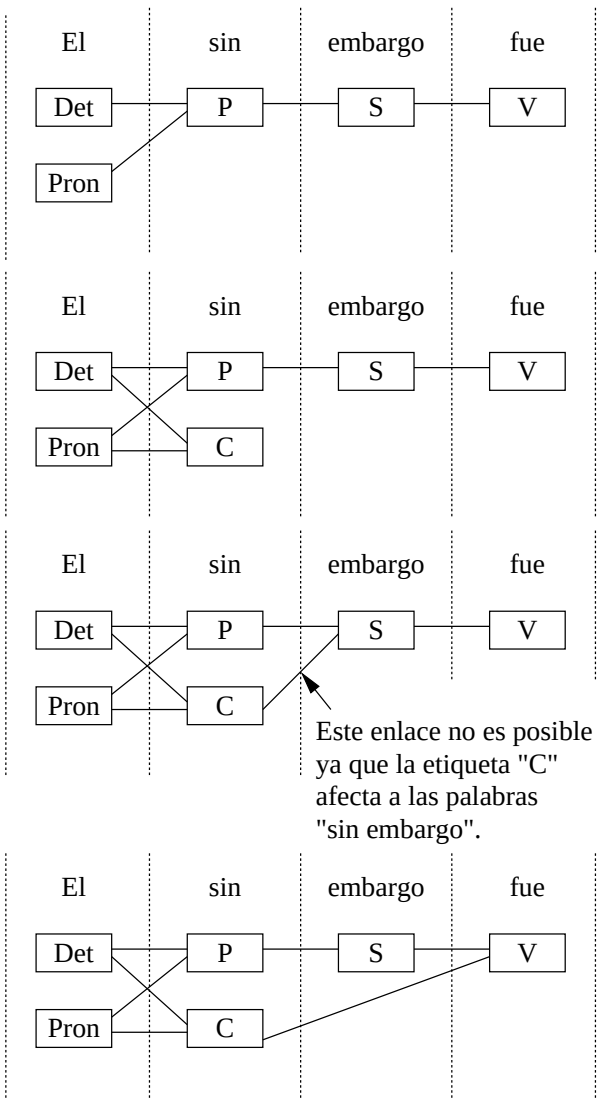

Figura 7.3: Evolución de la construcción del enrejado de Viterbi

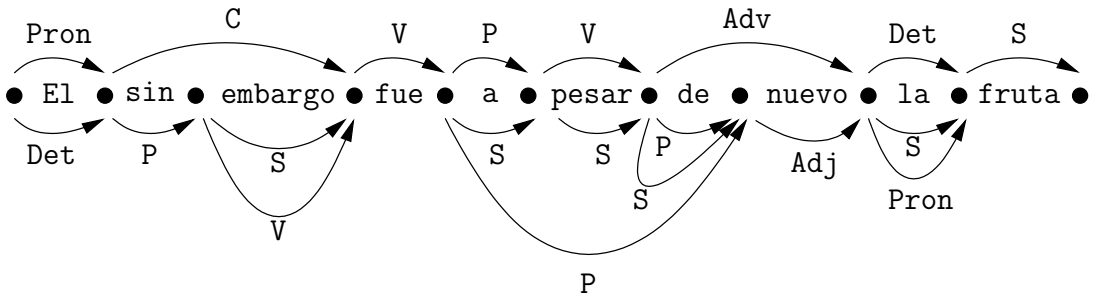

Figura 7.4: Retículo para la frase: `El sin embargo fue a pesar la fruta`

Como se ha indicado anteriormente lo que buscamos es una estructura lo más representativa posible para ilustrar nuestro problema, y con la que podamos trabajar de una manera sencilla y lógica. Esta forma de representación puede venir dada a través de la estructura matemática conocida como *retículo*. A continuación introducimos la definición formal de *retículo*.

Definición 7.1 Un *retículo* es una relación de orden parcial, donde dados dos elementos, éstos van a tener un *ínfimo*, que es el mayor elemento de todos los menores, y un *supremo*, que es el menor elemento de todos los mayores. □

Ahora, y de nuevo con un ejemplo, mostraremos la forma que tiene un *retículo* y su aplicación sobre el problema que estamos tratando, que básicamente consiste en numerar los huecos entre las palabras en lugar de las propias palabras.

Ejemplo 7.4 Supongamos que tenemos la frase: `El sin embargo fue a pesar de nuevo la fruta`. El retículo que representa todas las posibles segmentaciones y etiquetaciones correspondientes es el que se muestra en la figura 7.4. Tal y como podemos ver, los huecos entre las palabras que intervienen en la frase se corresponden con los puntos del retículo, y las arcos se corresponden con las posibles etiquetas de los distintos *tokens* que pueden dividir la frase. De esta manera, tal y como podemos apreciar en la figura, los caminos por los que se puede navegar y los posibles solapamientos entre ellos se representan de una manera más sencilla y manejable. □

7.2.2 Funcionamiento del algoritmo de Viterbi sobre un *retículo*

Llegados a este punto nos disponemos a estudiar, analizar y presentar el algoritmo de Viterbi modificado que opera sobre *retículos* [Brants 1999]. Como habíamos visto, antes una etiqueta abarcaba exactamente a una palabra. Ahora una etiqueta va a poder abarcar a un número arbitrario de palabras. Y además, va a cambiar la noción de estado, ya que en un *retículo* la etiqueta del arco que va de un punto a otro representa un estado, mientras que los puntos se corresponden con instantes de tiempo o, en nuestro caso, con los huecos que hay entre las palabras. De esta manera, cada arco del retículo se va representar con una tripla (t, t', q), donde t se corresponde con el instante de tiempo inicial, t' con el instante de tiempo final y q con el estado en cuestión.

Antes de abordar la descripción del algoritmo vamos a introducir las siguientes variables: $\Delta_{t,t'}(q)$ es la probabilidad máxima acumulada de llegar al estado q desde el instante de tiempo t hasta el instante de tiempo t', es decir, almacena la probabilidad del mejor camino que termina en el estado q empezando en el instante de tiempo t y terminando en el instante t'. Hablando en términos de NLP será la probabilidad máxima acumulada de llegar a la etiqueta q para las palabras que están entre el punto t y el punto t'. Y $\delta_{t,t'}(q)$ es la probabilidad de emisión del

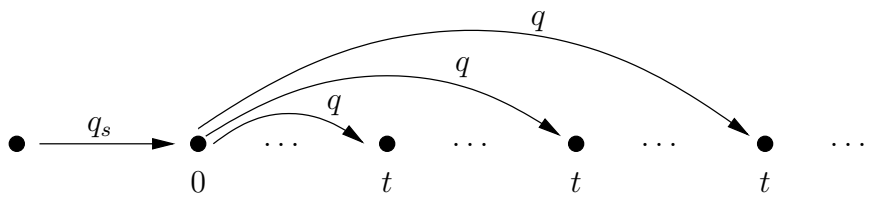

Figura 7.5: Primera extensión del algoritmo de Viterbi: Inicialización

estado q entre los instantes de tiempo t y t', en NLP es la probabilidad de que la etiqueta q emita la palabra o secuencia de palabras que hay entre los puntos t y t'.

Algoritmo 7.1 Primera extensión del algoritmo de Viterbi para que trabaje sobre *retículos*.

1. Inicialización:
   (ver figura 7.5)
   $$\Delta_{0,t}(q) = P(q|q_s)\delta_{0,t}(q).$$

2. Recursión:
   (ver figura 7.6)
   $$\Delta_{t,t'}(q) = \max_{(t'',t,q')\in Reticulo} \Delta_{t'',t}(q')P(q|q')\delta_{t,t'}(q), \qquad 1 \leq t < T. \tag{7.1}$$

3. Terminación:
   (ver figura 7.7)
   $$\max_{Q\in Q^*} P(Q, Reticulo) = \max_{(t,T,q)\in Reticulo} \Delta_{t,T}(q)P(q_e|q).$$

De forma adicional es necesario ir guardando el camino de las triplas que maximizan cada acumulador $\Delta_{t,t'}(q)$. Cuando alcancemos el instante de tiempo T, debemos recuperar la mejor tripla del *retículo*:

$$(t_1^m, T, q_1^m) = \arg \max_{(t,T,q)\in Reticulo} \Delta_{t,T}(q)P(q_e|q).$$

Siendo $t_0^m = T$, recuperamos los argumentos $(t'', t, q) \in Reticulo$ que maximizan la ecuación 7.1 avanzando hacia atrás en el tiempo:

$$(t_{i+1}^m, t_i^m, q_{i+1}^m) = \arg \max_{(t'',t_i^m,q')\in Reticulo} \Delta_{t'',t_i^m}(q')P(q_i^m|q')\delta_{t_i^m,t_{i-1}^m}(q_i^m),$$

desde $i \geq 1$, hasta alcanzar $t_k^m = 0$. De manera que, $q_1^m \dots q_k^m$ es el mejor camino de estados leído hacia atrás. □

Para que el algoritmo trabaje con la hipótesis de segundo orden, es decir, para que considere la dependencia no sólo del estado anterior, sino de los dos estados anteriores, el *retículo* se debe construir de manera que los estados estén formados por dos etiquetas, es decir, cada arco va a tener asociado dos etiquetas posibles, tal y como se muestra en la figura 7.8. De esta manera, los elementos que representan a una arista serán de la forma (t, t', q, q'), y para poder navegar de una arista a otra se debe de cumplir la siguiente condición: supongamos que tenemos los elementos (t'', t''', q'', q''') y (t, t', q, q'), y queremos pasar del instante t'' al instante t', en este caso se podrá transitar, si y sólo si, $q''' = q$ y $t''' = t$. Para hacernos una idea de la forma que tendría un *retículo* de segundo orden, podemos acudir a la figura 7.9, que se corresponde con el *retículo* de orden 2 para el ejemplo presentado anteriormente.

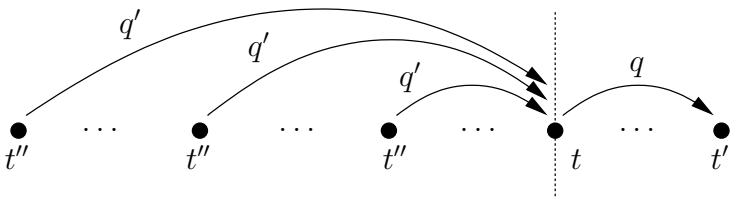

Figura 7.6: Primera extensión del algoritmo de Viterbi: Recursión

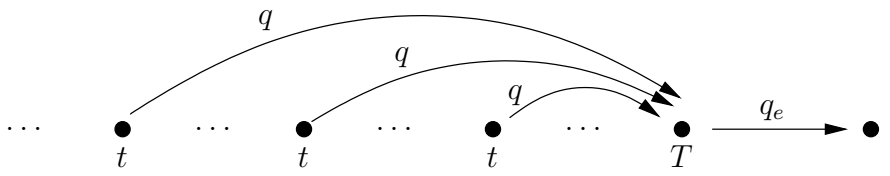

Figura 7.7: Primera extensión del algoritmo de Viterbi: Terminación

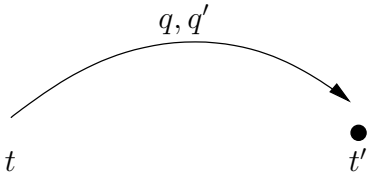

Figura 7.8: Forma de los arcos de los retículos de orden 2

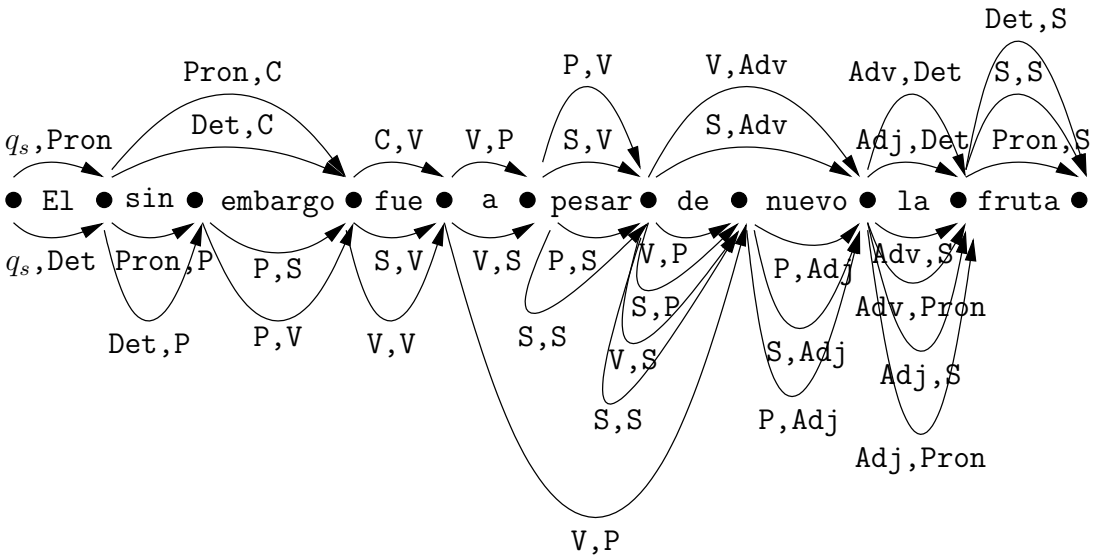

Figura 7.9: Retículo de orden 2 para el ejemplo

7.2.3 Etiquetación y segmentación combinada sobre el algoritmo de Viterbi

Hasta aquí hemos logrado que el algoritmo de Viterbi funcione con retículos y no con los enrejados clásicos habituales. Sin embargo, este algoritmo todavía no permite llevar a cabo la segmentación y la etiquetación de textos de manera combinada. Con este fin, debemos adaptar el nuevo algoritmo de Viterbi modificado para que trabaje con flujos de *tokens* de distinta longitud. Para ello, trabajaremos con la idea de mantener una serie de acumuladores Δ por cada camino de distinta longitud que nos conduce a un estado dado. De esta manera, cada uno de los arcos del retículo, que como vimos se corresponden con estados, va a poder tener asociado más de un acumulador. A continuación presentaremos el algoritmo que tiene en cuenta dicha mejora.

Algoritmo 7.2 Segunda extensión del algoritmo de Viterbi para que trabaje con flujos de *tokens* de distinta longitud.

1. Inicialización:
   (ver figura 7.5)
   $$\Delta_{0,t,1}(q) = P(q|q_s)\delta_{0,t}(q).$$
2. Recursión:
   (ver figura 7.6)
   $$\Delta_{t,t',l}(q) = \max_{(t'',t,q')\in Reticulo} \Delta_{t'',t,l-1}(q')P(q|q')\delta_{t,t'}(q), \qquad 1 \leq t < T. \tag{7.2}$$
3. Terminación:
   (ver figura 7.7)
   $$\max_{Q\in Q^*} P(Q, Reticulo) = \max_{l} \frac{\max\limits_{(t,T,q)\in Reticulo} \Delta_{t,T,l}(q)P(q_e|q)}{l}$$

Respecto a la fase de inicialización destacamos que al instante t llegaremos siempre con una longitud igual a 1. En la fase de recursión, sumamos uno a las longitudes de cada uno de los contadores cuyo estado tiene al instante t' como destino. Y en la fase de terminación nos quedaremos con el mejor de los caminos normalizados. Para ello obtenemos primero los mejores caminos normalizados de distinta longitud, y después elegimos el mejor.

De forma adicional, y al igual que en el algoritmo anterior, necesitamos mantener una traza con los elementos del *retículo* que maximizan cada $\Delta_{t,t'}(q)$.

Cuando se alcance el instante T, obtendremos la longitud del mejor camino del *retículo* de la siguiente manera:

$$L = \arg\max_{l} \frac{\max\limits_{(t,T,q)\in Reticulo} \Delta_{t,T,l}(q)P(q_e|q)}{l}$$

y, a continuación, para poder obtener el mejor último elemento de todos los caminos de longitud L, actuaremos como sigue (ver figura 7.10):

$$(t_1^m, T, q_1^m) = \arg \max_{(t,T,q)\in Reticulo} \Delta_{t,T,L}(q)P(q_e|q).$$

A continuación, para recolectar los argumentos (t'', t, q') que maximizan la ecuación 7.2, fijamos $t_0^m = T$ y caminando hacia atrás, hacemos lo siguiente (ver figura 7.11):

$$(t_{i+1}^m, t_i^m, q_{i+1}^m) = \arg \max_{(t'',t_i^m,q')\in Reticulo} \Delta_{t'',t_i^m,L-i}(q')P(q_i^m|q')\delta_{t_i^m,t_{i-1}^m}(q_i^m),$$

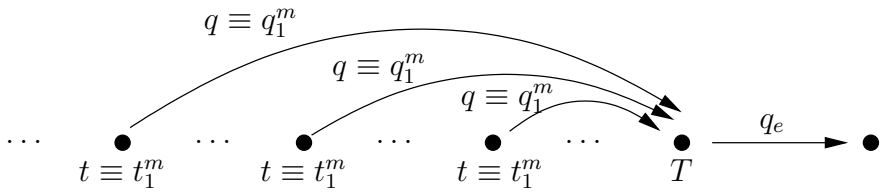

Figura 7.10: Mejor último elemento de todos los caminos de longitud L

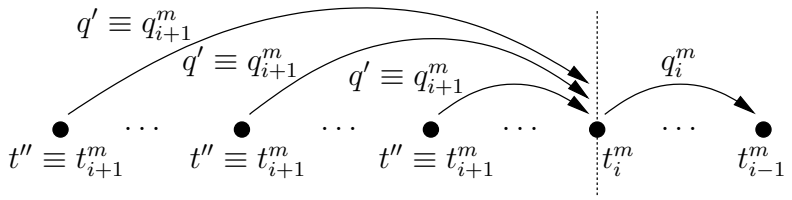

Figura 7.11: Recolección de los elementos que maximizan la ecuación 7.2

para $1 \leq i \leq k$, hasta alcanzar $t_k^m = 0$. Ahora $q_1^m, \ldots, q_k^m$ constituye la mejor secuencia de hipótesis (leída al revés). □

7.3 Cálculo de la complejidad

A continuación, con el propósito de hacer una comparativa de complejidades entre el algoritmo de Viterbi dinámico y el algoritmo de Viterbi clásico aplicado sobre *retículos*, vamos a realizar un análisis exhaustivo sobre el ejemplo que venimos estudiando, con lo cual, aconsejamos al lector que durante el presente estudio tenga en cuenta el *retículo* de la figura 7.4. Antes de nada, recordamos que el algoritmo dinámico se ejecuta sobre un *retículo* que contempla todos los caminos de distinta longitud por los que podemos navegar. Sin embargo, para poder ejecutar el algoritmo clásico necesitaremos que el *retículo* soporte caminos de una única longitud. De esta forma, el algoritmo se deberá ejecutar sobre distintos *retículos*, obteniendo para cada uno de ellos un camino óptimo, que a continuación normalizaremos para después quedarnos con el mejor de los caminos normalizados.

Para ambos algoritmos vamos a estudiar la **complejidad espacial** y la **complejidad temporal**, siendo para ello necesario el cálculo de los siguientes parámetros: el número de caminos posibles dentro del *retículo*, el número de longitudes diferentes que conforman dichos caminos, el número de acumuladores necesarios para cada estado del *retículo* y el número de operaciones realizadas para la obtención de dichos acumuladores.

Para el estudio de la complejidad espacial calcularemos el número de acumuladores necesarios que tenemos que almacenar. Para ello, en el algoritmo clásico tendremos tantos acumuladores como arcos existentes, mientras que en el algoritmo dinámico este número se calculará de la siguiente manera: cada arco tendrá tantos acumuladores como longitudes distintas tengan los caminos que pueden alcanzar su punto de origen.

En cuanto a la complejidad temporal, calcularemos el número de operaciones que debemos llevar a cabo. La forma de calcularlo es común a ambos algoritmos, y no es más que para cada arco, sumar el número de acumuladores de los arcos que pueden alcanzar su punto de origen.

A continuación estudiaremos ambos tipos de complejidad para el algoritmo de Viterbi dinámico. Para ello, y en función del *retículo* de la figura 7.4, calcularemos el número total de caminos

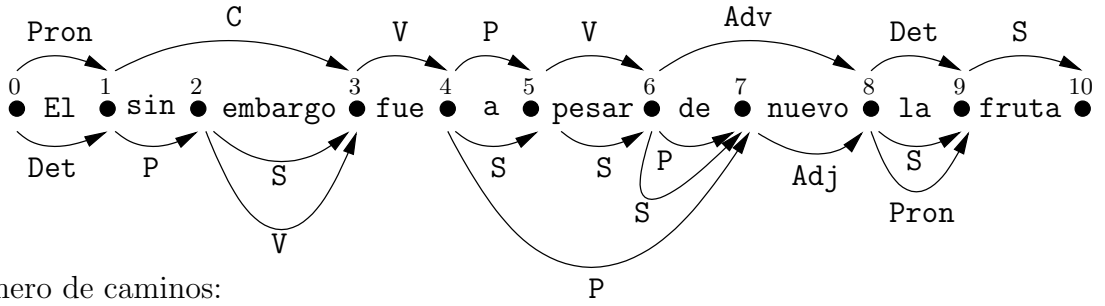

Numero de caminos:

234	117	78		39	39	18	9	3	3	1	1

Figura 7.12: Número de caminos para cada instante de tiempo del *retículo*

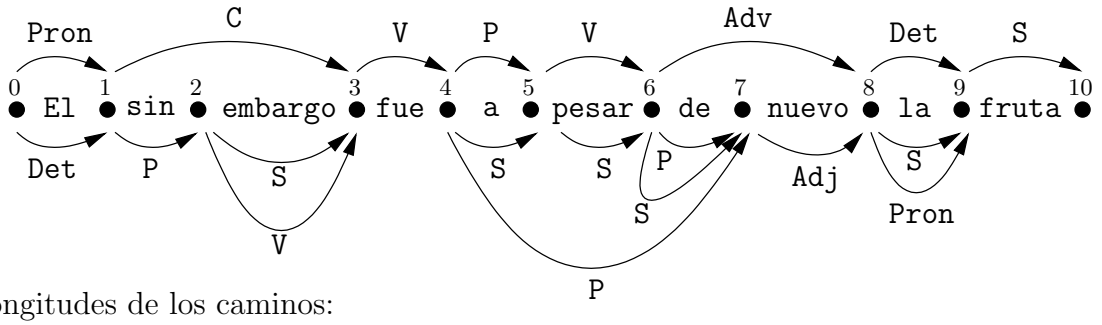

Longitudes de los caminos:

0	1	2		2	3	4	5	4	5	6	7
				3	4	5	6	5	6	7	8
								6	7	8	9
								7	8	9	10

Figura 7.13: Longitudes de los caminos para cada instante de tiempo del *retículo*

posibles, y lo haremos de la siguiente manera: viendo el *retículo* como un *autómata finito acíclico determinista* lo podemos convertir en un *autómata finito acíclico determinista numerado* tal y como se indica en la definición 2.8, de esta manera, obtenemos el número de caminos posibles desde el punto en el que nos encontramos hasta el instante final. Así, tal y como podemos ver en la figura 7.12, obtenemos un total de 234 caminos posibles.

A continuación calculamos la longitud de los caminos por los que podemos navegar, y para ello actuamos de la siguiente forma. En el instante inicial no tenemos ningún camino, con lo cual la longitud es 0. Para un instante de tiempo t distinto del inicial, deberemos tener en cuenta todos los arcos entrantes a dicho instante y quedarnos con todas las longitudes de los instantes origen del arco, a las que les sumamos uno. Así, para nuestro *retículo*, obtenemos un total de cuatro longitudes de caminos diferentes, que son 7, 8, 9 y 10, respectivamente. Dicha situación la podemos comprobar sobre el *retículo* de la figura 7.13, donde vamos calculando las longitudes de los caminos para cada instante de tiempo.

Con estas cifras ya podemos calcular el número total de acumuladores que el algoritmo dinámico necesita, para así determinar la complejidad espacial del algoritmo dinámico. De la misma manera, ya estamos en condiciones de calcular el número de operaciones necesarias, que nos va a determinar la complejidad temporal para dicho algoritmo. La forma en la que se calculan dichas cantidades se ha introducido anteriormente, con lo cual a continuación mostramos

los resultados obtenidos:

Origen	Arco	Destino	Longitudes en el origen	Nº acumuladores en el arco	Nº operaciones
0	Pron	1	0	1	1
0	Det	1	0	1	1
1	P	2	1	1	2
1	C	3	1	1	2
2	S	3	2	1	1
2	V	3	2	1	1
3	V	4	2,3	2	3
4	P	5	3,4	2	2
4	S	5	3,4	2	2
5	V	6	4,5	2	4
5	S	6	4,5	2	4
4	P	7	3,4	2	2
6	P	7	5,6	2	4
6	S	7	5,6	2	4
6	Adv	8	5,6	2	4
7	Adj	8	4,5,6,7	4	6
8	Det	9	5,6,7,8	4	6
8	Pron	9	5,6,7,8	4	6
8	S	9	5,6,7,8	4	6
9	S	10	6,7,8,9	4	12
				44	73

Como podemos observar, obtenemos un total de 44 acumuladores y de 73 operaciones, cifras que denotan la complejidad espacial y temporal, respectivamente, para el caso del algoritmo de Viterbi dinámico.

Una vez estudiada la complejidad para el caso dinámico, nos disponemos a estudiar la complejidad para el algoritmo clásico. Como indicamos anteriormente, si utilizamos esta aproximación el número de ejecuciones para este algoritmo viene determinado en función de las diferentes longitudes que pueden tener los caminos. Cada ejecución nos va a proporcionar un camino normalizado, y una vez obtenidos todos estos caminos normalizados elegiremos el mejor. Para reflejar este proceso, pensamos en una primera alternativa, la cual consiste en la construcción de un retículo para cada longitud de camino existente. De esta manera, empezamos a construir el retículo correspondiente para los caminos de longitud 7, tal y como podemos ver en la figura 7.14, resultando así un total de 6 caminos posibles. Continuamos ahora con la construcción del segundo retículo, donde tenemos en cuenta todos los caminos de longitud 8. Sin embargo, en este punto concluimos que esta idea no es buena, ya que se pueden producir solapamientos entre los caminos que pueden dar lugar, en el mismo retículo, a caminos de longitudes diferentes. En concreto, si nos fijamos en la figura 7.15, se puede apreciar que al intentar representar en un mismo *retículo* todos los caminos de longitud 8, surgen caminos de longitud 7, cuyas trazas se han marcado con los arcos punteados. Esto quiere decir que el algoritmo clásico no se puede aplicar, y que es necesario pensar en otra repartición de los posibles caminos en diferentes *retículos* de manera que no haya conflictos de longitud.

La alternativa correcta consiste en construir un árbol de decisión donde los nodos de ramificación involucren a los elementos conflictivos, es decir, a las palabras que pueden tener varias segmentaciones posibles. La figura 7.16 nos muestra el árbol de decisión que se corresponde

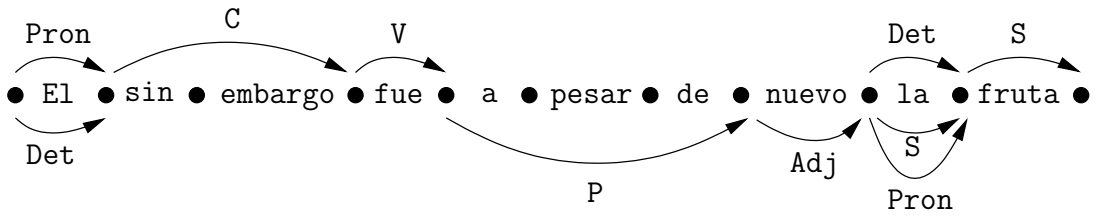

Figura 7.14: Caminos de longitud 7

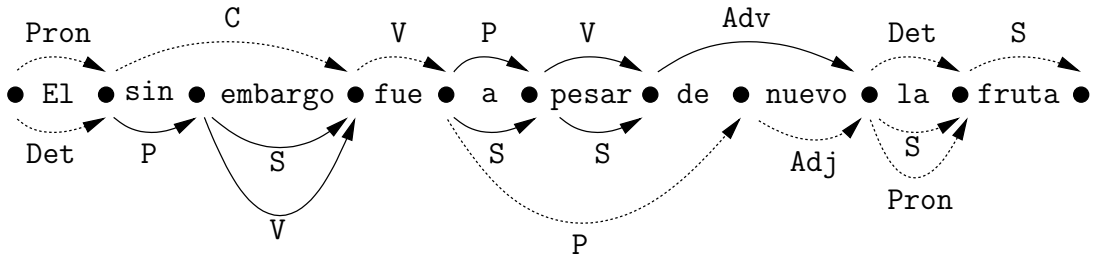

Figura 7.15: Caminos de longitud 8

con el retículo que venimos estudiando, a través del cual se deduce que son necesarios seis retículos y no cuatro, para representar todos los caminos sin que se produzcan solapamientos conflictivos como los indicados en la primera alternativa. Cabe destacar que nos podemos encontrar con varios *retículos* que contienen caminos de una misma longitud, pero efectivamente los caminos involucrados no se pueden representar sobre un mismo *retículo* sin dar lugar a conflictos. Veamos a continuación cuáles son estos retículos, así como los acumuladores y operaciones involucradas para cada uno de ellos, factores que se calculan de la misma forma que para el caso anterior. En la figura 7.17 tenemos el retículo para los caminos de longitud 7, obteniendo un total de 6 caminos posibles, 10 acumuladores y 13 operaciones . En la figura 7.18 mostramos el retículo para caminos de longitud 8, obteniendo para este caso 24 caminos, 13 acumuladores y 19 operaciones. En la figura 7.19 se encuentra el retículo que refleja los caminos de longitud 9, obteniendo un total de 48 caminos posibles, 15 acumuladores y 23 operaciones. De nuevo, en la figura 7.20 nos encontramos con otro retículo para los caminos de longitud 8, donde nos encontraremos con un total de 12 caminos, 12 acumuladores y 16 operaciones. Otra vez, en la figura 7.21 mostramos los caminos de longitud 9, dando un total de 48 caminos, 15 acumuladores y 22 operaciones. Y por último, en la figura 7.22 mostramos el retículo para los caminos de mayor longitud posible, 10, dando un total de 96 caminos, 17 acumuladores y 26 operaciones.

Con lo cual, para esta aproximación obtendremos un total de 82 acumuladores y 119 operaciones, valores que se corresponden con la complejidad espacial y temporal, respectivamente.

Ante las cifras obtenidas podemos ver claramente que la versión dinámica del algoritmo, para este caso, resulta mucho mejor, ya que nos encontramos con una complejidad espacial de 44 acumuladores frente a 82 que necesita la versión clásica. De igual manera, la complejidad temporal también ofrece mejores resultados, nos encontramos con un total de 36 operaciones frente a las 73 de la versión clásica. Con lo cual, como conclusión podemos determinar que esta versión del algoritmo promete mucho, aunque el trabajo al respecto todavía no está cerrado, aspecto en el que profundizaremos en el tema dedicado a las conclusiones.

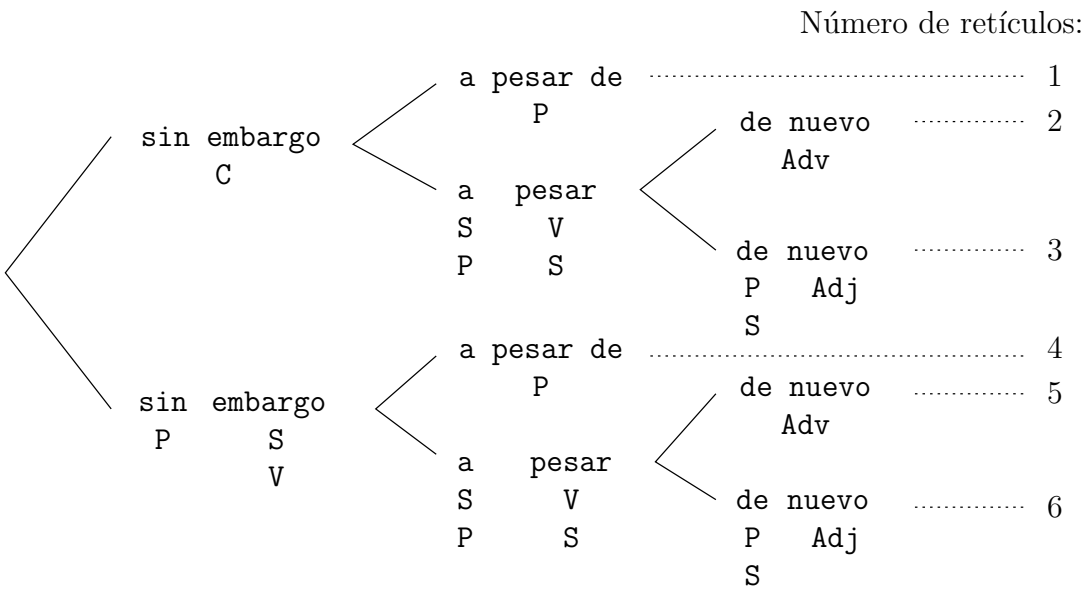

Figura 7.16: Árbol de decisión para las palabras conflictivas de la frase: `El sin embargo fue a pesar de nuevo la fruta`

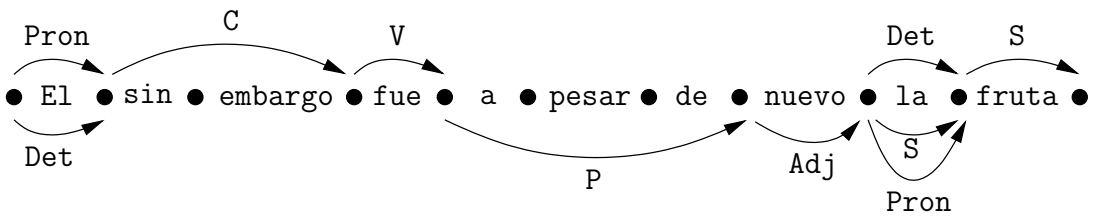

Figura 7.17: Retículo para caminos de longitud 7. Acumuladores = 10 y operaciones = 13

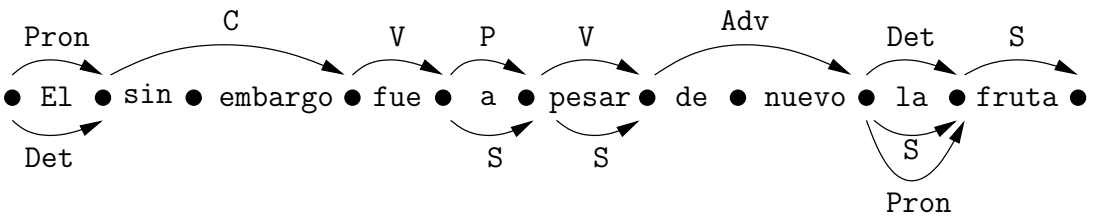

Figura 7.18: Retículo para caminos de longitud 8. Acumuladores = 13 y operaciones = 19

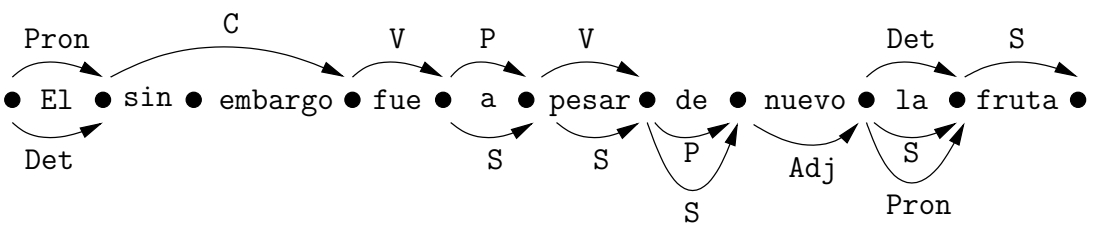

Figura 7.19: Retículo para caminos de longitud 9. Acumuladores = 15 y operaciones = 23

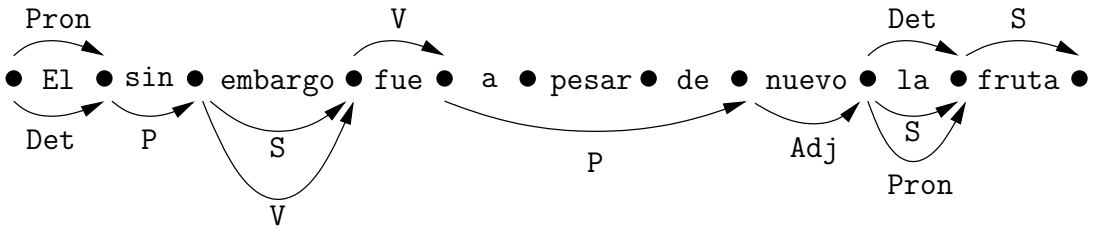

Figura 7.20: Retículo para caminos de longitud 8. Acumuladores = 12 y operaciones = 16

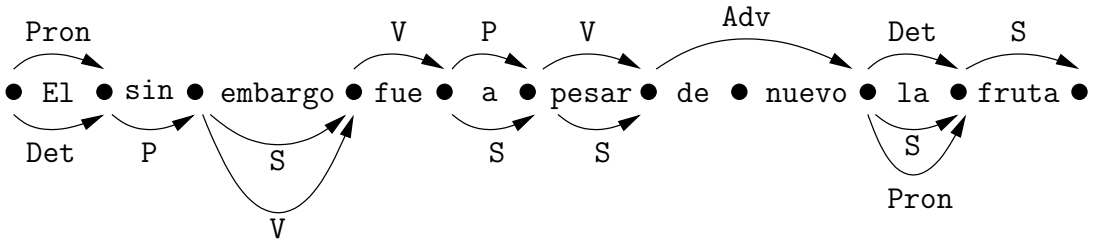

Figura 7.21: Retículo para caminos de longitud 9. Acumuladores = 15 y operaciones = 22

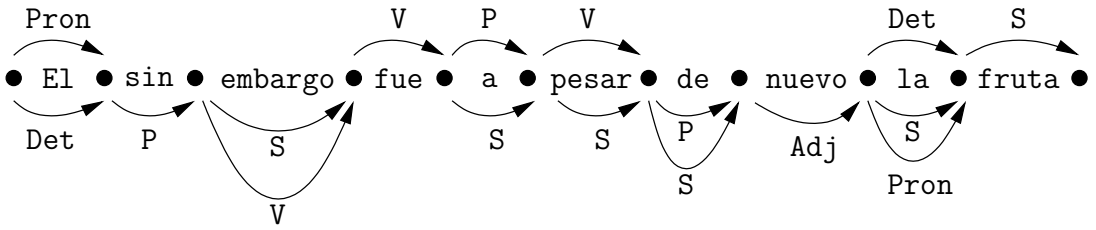

Figura 7.22: Retículo para caminos de longitud 10. Acumuladores = 17 y operaciones = 26

Capítulo 8

Conclusiones y trabajo futuro

Para poder llevar a cabo con garantías el proceso de etiquetación de textos en lenguaje natural, hemos visto que es indispensable tener en cuenta el contexto en el que aparecen cada una de las palabras del texto. Hemos estudiado diferentes métodos para modelizar dicho contexto, pero básicamente todos ellos los podemos agrupar en dos clases principales: los sistemas basados en modelos estocásticos, y los sistemas basados en reglas o transformaciones contextuales.

Todos los estudios realizados determinan que el marco probabilístico resulta más adecuado que las aproximaciones simbólicas, constituyendo así la aproximación que mejores rendimientos ofrece actualmente. Además, la adquisición de este tipo de *conocimiento máquina* se realiza de manera automática, y su aplicación resulta sencilla. No obstante, nos encontramos que los sistemas de etiquetación puramente estocásticos suelen etiquetar erróneamente alrededor del 2 ó 3% de las palabras de un texto dado. Por tanto, para poder enfrentarnos con garantías a este pequeño porcentaje de errores, es necesario añadir información de más alto nivel.

La fuente de esta información de más alto nivel puede ser el *conocimiento humano*. La experiencia que un lingüista puede aportar, mediante un pequeño conjunto de reglas contextuales elegidas apropiadamente, puede ser muy preciso en algunos ámbitos, y por lo tanto puede ayudar a mejorar apreciablemente el proceso de etiquetación. No obstante, la adquisición de este tipo de conocimiento y su aplicación exacta pueden resultar complejas.

Por este motivo, se busca el uso combinado de estos dos tipos de conocimiento. Aprovechando las ventajas que ambos nos ofrecen, se puede abordar el diseño de un sistema de alta precisión, el cual pasa por construir un sistema híbrido que combine las dos estrategias consideradas anteriormente: los modelos estocásticos y los modelos basados en reglas contextuales.

Con el objetivo de mejorar estos resultados de etiquetación gran parte del esfuerzo desarrollado en este proyecto se ha dedicado al estudio y al análisis de la sintaxis de los sistemas de etiquetación basados en reglas de restricciones, hoy en día considerados los de mayor exponente en sistemas de etiquetación híbridos. Este proyecto no sólo constituye un intento de mejorar la comprensión de las gramáticas de restricciones, mediante la simplificación de la sintaxis de las mismas, sino que también se preocupa de abordar la compilación y la ejecución de las reglas de la forma más eficiente posible. A este nivel las aportaciones de este proyecto se centran en los siguientes puntos:

- Se ha mejorado la sintaxis del formalismo de reglas del lenguaje LEMERS [Reboredo y Graña 2000], con el propósito de hacer los esquemas generales de reglas contextuales más intuitivos y fáciles de entender. De esta manera se consigue una aceptación más positiva de las gramáticas de restricciones por parte de los lingüistas.

- Se ha llevado a cabo la compilación y la ejecucion de estas reglas de la forma más eficiente

posible. Para ello nos hemos ayudado de la estructura matemática que recibe el nombre de *traductor de estado finito*.

Se han observado que estas aportaciones se traducen, efectivamente, en mejoras de expresividad por un lado, y en mejoras de rendimiento por otro. Como conclusiones importantes podemos afirmar lo siguiente:

- La expresividad de las reglas contextuales ha mejorado tanto que prácticamente las reglas hablan por sí mismas, ayudándonos para ello de la teoría de conjuntos. Sin embargo, aclaramos que el trabajo a este nivel no está todavía cerrado ya que son los usuarios finales los que deben tomar las últimas decisiones de diseño. No obstante, el formalismo desarrollado se ha modificado de tal manera que se sigue manteniendo la flexibilidad que presentaban las antiguas reglas de las gramáticas de restricciones.

- La compilación y la ejecución de las reglas contextuales resulta eficiente, obteniendo además los mismos resultados que cabrían esperar al ejecutar cada una de las reglas separadas y de forma secuencial. La única desventaja que hemos detectado es que el tamaño de los traductores compilados y normalizados no es tan compacto como esperábamos en un principio. Sin embargo, este pequeño problema puede deberse a alguno de los siguientes motivos:

  - La propia naturaleza y estructura de los traductores.
  - La operación de composición sobre traductores de estado finito es compleja e involucra un gran coste computacional.
  - La forma de representación interna de los traductores que utiliza la herramienta en la que nos hemos apoyado. A esto también se le debe unir la manera en que realiza las operaciones sobre los traductores, que probablemente se lleven a cabo optimizando la complejidad temporal, pero no la espacial. En este sentido resultaría interesante, y lo proponemos como trabajo futuro, el estudio, la evaluación y la comparación con otras herramientas disponibles, o la reflexión sobre la conveniencia de realizar una implementación propia a este nivel.

- El prototipo desarrollado podría resultar interesante orientearlo a la detección de errores sistemáticos que producen los etiquetadores. Es decir, a partir de los errores que acostumbran a cometer los etiquetadores, se podría intentar generar automáticamente las reglas contextuales que los corrigen, de manera que al aplicar dichas reglas sobre la salida del etiquetador estos errores serían eliminados.

Antes de finalizar, consideramos interesante recordar que uno de los mayores inconvenientes de los sistemas de etiquetación es que los resultados obtenidos dependen en exceso del estilo de los textos que se han utilizado para su entrenamiento. Actualmente, se ha demostrado que la forma de paliar este problema es a través del diseño de sistemas híbridos. Este tipo de técnicas es el único que permite la incorporación de información capaz de enfrentarse a los errores sistemáticos que cometen los etiquetadores tradicionales, y a los fenómenos lingüísticos no correctamente formalizados.

El segundo objetivo de este proyecto aborda la formalización del proceso de segmentación. Por un lado, hemos visto que los etiquetadores actuales asumen que el texto de entrada aparece ya correctamente segmentado, es decir, dividido de manera adecuada en *tokens*. Esta hipótesis de trabajo no es realista debido a la naturaleza heterogénea de los textos y a la gran fenomenología

que presentan los léxicos de los idiomas de aplicación. Por otra parte, hemos visto también que el proceso de segmentación es una tarea de enorme importancia práctica y que abordarla con pleno rigor científico, sin caer repetidamente en el análisis de la casuística particular de cada fenómeno detectado, es una labor que resulta especialmente compleja.

Los mayores problemas surgen cuando el módulo preprocesador detecta ambigüedades en el proceso de segmentación. Esta es la situación en la que la solución que se hemos diseñado adquiere su mayor utilidad, y la reflexión que subyace en la idea propuesta es sencilla:

- A este nivel, pensamos que un preprocesador no debería de ir más allá de la simple detección y preetiquetación de cada una de las alternativas de segmentación.

- Y, por tanto, la elección de una de ellas debe de hacerse en función del contexto, que es precisamente lo que estudia el etiquetador.

Así pues, y con este objetivo en mente, hemos diseñado una serie de extensiones sobre el algoritmo de clásico de Viterbi:

- Primeramente, se ha extendido el algoritmo para que pueda trabajar sobre retículos, debido a que los enrejados clásicos no son capaces de representar las dependencias solapadas que pueden aparecer entre las distintas alternativas de segmentación.

- El algoritmo que trabaja sobre retículos se extendió después para poder seguir trabajando con la hipótesis de segundo orden, es decir, la que considera la dependencia no sólo del estado anterior, sino de los dos anteriores.

- Finalmente, se incorporó al algoritmo una normalización dinámica basada en la longitud de los caminos, para evitar que los caminos más cortos se vieran favorecidos sobre los más largos.

Posteriormene, se ha demostrado que el algoritmo propuesto es equivalente a la aplicación individual del algoritmo clásico sobre las diferentes alternativas de segmentación, y que proporciona la misma elección que la que realizaría la posterior normalización de dichas alternativas en función de sus longitudes.

Se ha realizado también un estudio intuitivo de la complejidad espacial y temporal del algoritmo propuesto, y se ha visto que, al menos en este contexto, es comparable a la del algoritmo clásico y, por supuesto, inferior a la complejidad total que involucran las sucesivas aplicaciones individuales del algoritmo clásico sobre todas las posibles segmentaciones.

No obstante, el trabajo no está todavía cerrado, y queda pendiente la consideración de los siguientes aspectos:

- Es cierto que la principal aportación de este nuevo algoritmo se centra en la formalización del proceso de segmentación. Sin embargo, no se ha podido realizar una evaluación exhaustiva del algoritmo, debido sobre todo a la escasa disponibilidad de textos en los que aparezcan un conjunto de segmentaciones ambiguas verdaderamente representativo. Como ya se ha comentado anteriormente, este tipo de problemas es muy frecuente cuando los textos de aplicación están escritos en gallego, y los recursos lingüísticos disponibles para este idioma son prácticamente inexistentes. En otras palabras, queda por comprobar que el algoritmo propuesto efectivamente resuelve bien el problema para el que ha sido concevido. No obstante, ha quedado diseñado un eficiente marco para tal fin, el cual además constituye una aproximación muy elegante a la tarea de segmentación, porque libera al módulo preprocesador de toda la casuística que aparece a este nivel.

- Por otra parte, existe otro tipo de algoritmos iterativos capaces de trabajar sobre retículos que contienen caminos de diferentes longitudes. Por tanto, el estudio de complejidad debe ser completado con la comparación de nuestro algoritmo con esos otros. No obstante, dicha comparación no es trivial, ya que primero hay que salvar la dificultad de adaptar esos algoritmos al contexto de la etiquetación.

- Por último, es necesario comentar que esta segunda fase del trabajo presentado ha sido tratada de manera totalmente aislada. Es decir, no hemos hablado en ningún momento de cómo podrían convivir juntos los dos objetivos que se han cubierto en este proyecto. Precisamente, como parte del trabajo futuro, quedaría también el estudiar la manera de integrar el uso de reglas contextuales sobre retículos.

En cualquier caso, bajo estas hipótesis de trabajo, y a falta de realizar y comprobar todos las cuestiones anteriormente comentadas, creemos que es posible afirmar que se ha alcanzado un punto en el cual el proceso de etiquetación no podrá avanzar mucho más allá en un futuro inmediato.

Vive como si fueras a morir mañana.
Aprende como si fueras a vivir siempre.

Parte V

Apéndices y bibliografía

Apéndice A

Juegos de etiquetas

Este apéndice describe sólo las etiquetas utilizadas en los ejemplos incluidos en el presente trabajo. Como ya se ha mencionado anteriormente, dichas etiquetas provienen de los *tag sets* utilizados en los proyectos Galena y Corga. Una descripción completa de ambos *tag sets* puede encontrarse a partir de [Vilares *et al.* 1995] y [Vilares *et al.* 1998], respectivamente. Más información sobre estos proyectos está disponible también en `http://coleweb.dc.fi.udc.es`.

A.1 Etiquetas Galena

Afp0	Adjetivo femenino plural no aplicable
Amp0	Adjetivo masculino plural no aplicable
Ams0	Adjetivo masculino singular no aplicable
Ncyyp	Numeral cardinal tanto in/determinado plural
P	Preposición
P31	Primer elemento de una preposición de tres elementos
P32	Segundo elemento de una preposición de tres elementos
P33	Tercer elemento de una preposición de tres elementos
Re3sam	Pronombre enclítico acusativo masculino tercera persona del singular
Re3yyy	Pronombre enclítico acusativo o dativo masculino o femenino tercera persona
Scfp	Sustantivo común femenino plural
Scfs	Sustantivo común femenino singular
Scmp	Sustantivo común masculino singular
Scms	Sustantivo común masculino plural
V000f0	Verbo infinitivo
V000f0PE1	Verbo infinitivo con un pronombre enclítico
V2pei0	Verbo pretérito de indicativo segunda persona del plural
V2sei0	Verbo pretérito de indicativo segunda persona del singular
V2spm0	Verbo presente de imperativo segunda persona del singular
V3spi0	Verbo presente de indicativo tercera persona del singular
Vysci0	Verbo condicional de indicativo primera y tercera persona del singular
Vysii0	Verbo imperfecto de indicativo primera y tercera persona del singular
Vysps0	Verbo presente de subjuntivo primera y tercera persona del singular

A.2 Etiquetas CORGA

Ddms	Artículo determinante masculino singular
P	Preposición
Raa3ms	Pronombre átono acusativo masculino tercera persona del singular
Scms	Sustantivo común masculino singular
Vpi2s0	Verbo presente indicativo segunda persona del singular

Bibliografía

Abney, S. (1996). Part-of-speech tagging and partial parsing. In S. Young and G. Bloothooft (eds.), *Corpus-Based Methods in Language and Speech Processing*, pp. 118-136. Dordrecht: Kluwer Academic.

Aho, A.V.; Sethi, R.; Ullman, J.D. (1985). Compilers: principles, techniques and tools. *Addison-Wesley*, Reading, MA.

Alvarez Rosario; Regueira X. L.; Motegudo H. (1Alvarez86986). Gramática Galega. *Ediciones Galaxia*.

Bahl, L.R.; Mercer, R.L. (1976). Part-of-speech assignement by a statistical decision algorithm. In *International Symposium on Information Theory*, Ronneby (Sweden).

Baker, J.K. (1975). Stochastic modeling for automatic speech undestanding. In D. Raj Reddy (ed.), *Speech Recognition: Invited papers presented at the 1974 IEEE symposium*, pp. 297-307. Academic Press, NY.

Baldi, P.; Brunak, S. (1998). Bioinformatics: the machine learning approach. *The MIT Press*, Cambridge, MA.

Brants, Thorsten (1999) Cascaded Markov Models. Universität des Saarlandes, Computerlinguistik. D-66041 Saarbrücken, Germany.

Baum, L.E.; Petrie, L.; Soules, G.; Weiss, N. (1970). A maximization technique ocurring in the statistical analysis of probabilistic functions of Markov chains. *Annals of Mathematical Statistics*, vol. 41, pp. 164-171.

Baum, L.E. (1972). An inequality and associated maximization technique in statistical estimation for probabilistic functions of Markov processes. *Inequalities*, vol. 3, pp. 1-8.

Benello, J.; Mackie, A.W.; Anderson, J.A. (1989). Syntactic category disambiguation with neural networks. *Computer Speech and Language*, vol. 3, pp. 203-217.

Brants, T. (1998). Estimating hidden Markov model topologies. In J. Ginzburg, Z. Khasidashvili, C. Vogel, J.-J. Lévy and E. Vallduví (eds.), *The Tbilisi Symposium on Logic, Language and Computation: Selected Papers*, pp. 163-176. *CSLI Publications*, Stanford, CA.

Brants, T. (2000). TnT - A statistical part-of-speech tagger. In *Proceedings of the Sixth Applied Natural Language Processing Conference (ANLP-2000)*, Seattle, WA.

Brill, E. (1993a). Automatic grammar induction and parsing free text: a transformation-based approach. In *Proceedings of the 31st Annual Meeting of the Association for Computational Linguistics*, pp. 259-265.

Brill, E. (1993b). A corpus-based approach to language learning. *PhD. Thesis*, University of Pennsylvania.

Brill, E. (1993c). Tansformation-based error-driven parsing. In *Proceedings of the Third International Workshop on Parsing Technologies*, Tilburg/Durbuy (The Netherlands/Belgium).

Brill, E. (1994). Some advances in rule-based part of speech tagging. In *Proceedings of the Twelfth National Conference on Artificial Intelligence (AAAI-94)*, Seattle, WA.

Brill, E. (1995a). Transformation-based error-driven learning and natural language processing: a case study in part-of-speech tagging. *Computational Linguistics*, vol. 21, pp. 543-565.

Brill, E. (1995b). Unsupervised learning of disambiguation rules for part of speech tagging. In *Proceedings of the Third Workshop on Very Large Corpora*, pp. 1-13.

Brill, E.; Magerman, D.M.; Marcus, M.P.; Santorini, B. (1990). Deducing linguistic structure from the statistics of large corpora. In M. Kaufmann (ed.), *Proceedings of the DARPA Speech and Natural Language Workshop*, pp. 275-282, San Mateo, CA.

Brill, E.; Resnik, P. (1994). A transformation-based approach to prepositional phrase attachment disambiguation. In *Proceedings of the 15th International Conference on Computational Linguistics (COLING-94)*, pp. 1198-1204.

Brown, P.F.; Della Prieta, S.A.; Della Prieta, V.J.; Mercer, R.L.; Resnik, P.S. (1991). Language modelling using decision trees. *IBM Research Report*, Yorktown Heights, NY.

Burke, R.; Hammond, K.; Kulyukin, V.; Lytinen, S.; Tomuro, N.; Schoenberg, S. (1997). Question answering form frequently asked files. *AI Magazine*, vol. 18, pp. 57-66.

Cardie, C. (1997). Empirical methods in information extraction. *AI Magazine*, vol. 18, pp. 65-79.

Chanod, J.-P.; Tapanainen, P. (1995). Tagging French - comparing a statistical and a constraint-based method. In *Proceedings of the 7th Conference of the European Chapter of the Association for Computational Linguistics*, pp. 149-156.

Charniak, E. (1993). Statistical language learning. *The MIT Press*, Cambridge, MA.

Charniak, E. (1997). Statistical parsing with a context-free grammar and word statistics. In *Proceedings of the Fourteenth National Conference on Artificial Intelligence (AAAI'97)*, pp. 598-603.

Charniak, E.; Hendrickson, C.; Jacobson, N.; Perkowitz, M. (1993). Equations for part-of-speech tagging. In *Proceedings of the Eleventh National Conference on Artificial Intelligence*, pp. 784-789. Menlo Park, CA.

Chomsky, N. (1957). Syntactic structures. The Hague: Mouton.

Church, K.W. (1988). A stochastic parts program and noun phrase parser for unrestricted text. In *Proceedings of the Second Conference on Applied Natural Language Processing*, pp. 136-143.

Daciuk, J.; Mihov, S.; Watson, B.W.; Watson, R.E. (2000). Incremental construction of minimal acyclic finite-state automata. *Computational Linguistics*, vol. 26(1), pp. 3-16.

Daelemans, W.; Zavrel, J.; Berck, P.; Gillis, S. (1996). MBT: A memory-based part of speech tagger generator. In *Proceedings of the Fourth Workshop on Very Large Corpora*, pp. 14-27.

DeRose, S.J. (1988). Grammatical category disambiguation by statistical optimization. *Computational Linguistics*, vol. 14, pp. 31-39.

Dempster, A.P.; Laird, N.M.; Rubin, D.B. (1977). Maximum likelihood from incomplete data via the EM algorithm. *J. Roy. Stat. Soc.*, vol. 39(1), pp. 1-38.

Derouault, A.-M.; Merialdo, B. (1986). Natural language modeling for phoneme-to-text transcription. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 8, pp. 642-649.

Dini, L.; Di Tomaso, V.; Segond, F. (1998). Error-driven word sense disambiguation. In *Proceedings of the 36th Annual Meeting of the Association for Computational Linguistics/17th International Conference on Computational Linguistics (COLING-98)*, pp. 320-324.

Durbin, R.; Eddy, S.; Krogh, A.; Mitchison, G. (1998). Biological sequence analysis: probabilistic models of proteins and nucleic acids. *Cambridge University Press.*

Elworthy, D. (1994). Does Baum-Welch re-estimation help taggers? In *Proceedings of the Fourth Conference on Applied Natural Language Processing*, pp. 53-58.

Fagan, J.L. (1987). Automatic phrase indexing for document retrieval: an examination of syntactic and non-syntactic methods. In *Proceedings of the 10th Annual International ACM/SIGIR Conference on Research and Development in Information Retrieval.*

Forney, G.D. (1973). The Viterbi algorithm. In *Proceedings of the IEEE*, vol. 61 (March), pp. 268-278.

Foster, G.F. (1991). Statistical lexical disambiguation. *Master's thesis*, School of Computer Science, McGill University.

Francis, W.N.; Kučera, H. (1982). Frequency analysis of English usage. *Houghton Mifflin Company*, Boston, MA.

Franz, A. (1996). Automatic ambiguity resolution in natural language processing. *Lecture Notes in Artificial Intelligence*, vol. 1171, Springer Verlag, Berlin.

Franz, A. (1997). Independence assumptions considered harmful. In *Proceedings of the 35th Annual Meeting of the Association for Computational Linguistics/8th Conference of the European Chapter of the Association for Computational Linguistics*, pp. 182-189.

Garside, R.G.; Leech, G.N.; Sampson, G.R. (eds.) (1987). The computational analysis of English: a corpus-based approach. *Longman*, London.

González Collar, A.L.; Goñi Menoyo, J.M.; González Cristóbal, J.C. (1995). Un analizador morfológico para el castellano basado en chart. En *Actas de la VI Conferencia de la Asociación Española para la Inteligencia Artificial (CAEPIA'95)*, Alicante, pp. 343-352.

Graña Gil, J.; Alonso Pardo, M.A.; Valderruten Vidal, A. (1994). Análisis léxico no determinista: etiquetación eficiente del lenguaje natural. *Technical Report* 16, Departamento de Computación, Universidad de A Coruña.

Graña Gil, J. (2000). Técnicas de Análisis Sintáctico Robusto para la Etiquetación del Lenguaje Natural. *Tesis Doctoral*, Departamento de Computación, Universidad de A Coruña.

Greene, B.B.; Rubin, G.M. (1971). Automatic grammatical tagging of English. *Technical Report*, Brown University, Providence, RI.

Hopcroft, J.E.; Ullman, J.D. (1979). Introduction to automata theory, languages and computations. *Addison-Wesley*, Reading, MA.

Jacquemin, C.; Klavans, J.L.; Tzoukermann, E. (1997). Expansion of multi-words terms for indexing and retrieval using morphology and syntax. In *Proceedings of the 35th Annual Meeting of the Association for Computational Linguistics/8th Conference of the European Chapter of the Association for Computational Linguistics*, pp. 24-31.

Jelinek, F. (1976). Continuous speech recognition by statistical methods. *IEEE*, vol. 64, pp. 532-556.

Jelinek, F. (1985). Markov source modeling of text generation. In J.K. Skwirzynski (ed.), *The Impact of Processing Techniques on Communications*, E91 of *NATO ASI series*, pp. 569-598. Dordrecht: M. Nijhoff.

Jelinek, F. (1997). Statistical methods for speech recognition. *The MIT Press*, Cambridge, MA.

Jelinek, F.; Bahl, L.R.; Mercer, R.L. (1975). Design of a linguistic statistical decoder for the recognition of continuous sppech. *IEEE Transactions on Information Theory*, vol. 21, pp. 250-256.

Karlsson, F.; Voutilainen, A.; Heikkilä, J.; Anttila, A. (1995). Constraint grammar: a language-independent system for parsing unrestricted text. *Mouton de Gruyer*, Berlin.

Karttunen, L.; Beesley, K. (1992). Two-level rule compiler. *Technical Report* ISTL-92-2, Xerox, Palo Alto Research Center, CA.

Kempe, A. (1997). Finite states transducers approximating hidden Markov models. In *Proceedings of the 35th Annual Meeting of the Association for Computational Linguistics/8th Conference of the European Chapter of the Association for Computational Linguistics*, pp. 460-467.

Klein, S.; Simmons, R.F. (1963). A computational approach to grammatical coding of English words. *Journal of the Association for Computing Machinery*, vol. 10, pp. 334-347.

Koskennimi, K. (1983). Two-level morphology: A general computational model for word-form recognition and production. *Publications* 11, Department of General Linguistics, University of Helsinki.

Kupiec, J. (1992). Robust part-of-speech tagging using a Hidden Markov Model. *Computer Speech and Language*, vol. 6, pp. 225-242.

Kupiec, J. (1993). MURAX: A robust linguistic approach for question answering using an on-line encyclopedia. In *Proceedings of the 16th Annual International ACM/SIGIR Conference on Research and Development in Information Retrieval*, pp. 181-190.

Levinson, S.E.; Rabiner, L.R.; Sondhi, M.M. (1983). An introduction to the application of the theory of probabilistic functions of a Markov process to automatic speech reconigtion. *Bell System Technical Journal*, vol. 62, pp. 1035-1074.

Lucchesi, C.L.; Kowaltowski, T. (1993). Applications of finite automata representing large vocabularies. *Software - Practice and Experience*, vol. 23(1), pp. 15-30.

Markov, A.A. (1913). An example of statistical investigation in the text of Eugene Onyegin illustrating coupling of tests in chains. In *Proceedings of the Academy of Sciences, St. Petersburg*, vol. 7 of VI, pp. 153-162.

Marques, N.C.; Pereira Lopes, G. (1996). A neural network approach to part-of-speech tagging. In *Proceedings of the XIII Simpósio Brasileiro de Inteligência Artificial (SBIA-96)*, Ciuritiba (Brasil).

Màrquez, L.; Padró, L. (1997). A flexible POS tagger using an automatically acquired language model. In *Proceedings of joint ACL/EACL-97*, Madrid.

Màrquez, L.; Rodríguez, H. (1997). Automatically acquiring a language model for POS tagging using decision trees. In *Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP-97)*, Tzigov Chark (Bulgaria).

Marshall, I. (1987). Tag selection using probabilistic methods. In R. Garside, G. Leech and G. Sampson (eds.), *The computational analysis of English: a corpus-based approach*, pp. 42-65. Longman, London.

McMahon, J.G.; Smith, F.J. (1996). Improving statistical language model performance with automatically generated word hierarchies. *Computational Linguistics*, vol. 22, pp. 217-247.

Merialdo, B. (1994). Tagging English text with a probabilistic model. *Computational Linguistics*, vol. 20, pp. 155-171.

Mikheev, A. (1997). Automatic rule induction for unknown-word guessing. *Computational Linguistics*, vol. 23(3), pp. 405-423.

Miller, D.; Leek, T.; Schwartz, R. (1999). A hidden Markov model information retrieval system. In *Proceedings of the 22nd. Annual International ACM/SIGIR Conference on Research and Development in Information Retrieval*, pp. 214-221.

Mohri, M. (1995). On some applications of finite-state automata theory to natural language processing. *Natural Language Engineering*, Cambridge University Press, vol. 1(1), pp. 1-21.

Mohri, M. (1997). Finite-state transducers in language and speech processing. *Computational Linguistics*, vol. 23(2), pp. 269-311.

Moreno Sandoval, A. (1991). Un modelo computacional basado en la unificación para el análisis y la generación de la morfología del español. *Tesis Doctoral*, Departamento de Lingüística, Lenguas Modernas, Lógica y Filosofía de la Ciencia, Universidad Autónoma de Madrid.

Moreno Sandoval, A.; Goñi Menoyo, J.M. (1995). GRAMPAL: A morphological model and processor for Spanish implemented in Prolog. In M. Sessa and M. Alpuente (eds.), *Proceedings of the Joint Conference on Declarative Programming (GULP-PRODE'95)*, Marina di Vietri (Italy), pp. 321-331.

Oflazer, K.; Tür, G. (1996). Combining Hand-crafted Rules and Unsupervised Learning in Constraint-based Morphological Disambgiguation. *Departament of Computer Engineering and Information Science Bilkent University, Bilkent, Ankara, TR-06533*, TURKEY.

Padró, L. (1996). POS tagging using relaxation labelling. In *Proceedings of the 16th International Conference on Computational Linguistics (COLING-96)*, Copenhagen, Denmark.

Porta, J. (1996). RTAG. *Technical Report*, Grupo de Investigación de Lingüística Computacional, Universidad de Barcelona.

Rabiner, L. (1989). A tutorial on hidden Markov models and selected applications in speech recognition. In *Proceedings of the IEEE*, vol. 77, pp. 257-286.

Rabiner, L.; Juang, B.H. (1993). Fundamentals of speech recognition. *Prentice-Hall*, Englewood Cliffs, NJ.

Ramshaw, L.A.; Marcus, M.P. (1994). Exploring the statistical derivation of transformational rules sequences for part-of-speech tagging. In *The Balancing Act. Proceedings of the Workshop*, Association of Computational Linguistics, pp. 86-95, Morristown, NJ.

Reboredo, J. A. (2000) Diseño e implementación de un entorno de eliminación de ambigúedades léxicas basado en restricciones sintácticas. *Proyecto Fin de Carrere en Ingeniería Informática.*

Revuz, D. (1992). Minimization of acyclic deterministic automata in linear time. *Theoretical Computer Science*, vol. 92(1), pp. 181-189.

Ristad, E.S.; Thomas, R.G. (1997). Hierarchical non-emitting Markov models. In *Proceedings of the 35th Annual Meeting of the Association for Computational Linguistics/8th Conference of the European Chapter of the Association for Computational Linguistics*, pp. 381-385.

Roche, E.; Schabes, Y. (1995). Deterministic part-of-speech tagging with finite-state transducers. *Computational Linguistics*, vol. 21(2), pp. 227-253.

Roche, E.; Schabes, Y. (1997). Finite-state language precessing. *The Massachusetts Institute of Fechnology*, pp. 14-63.

Russell, G.; Petitpierre, D. (1995). MMORPH - The Multext Morphology Program, version 2.3. *MULTEXT deliverable report.*

Salton, G.; Thorpe, R.W. (1962). An approach to the segmentation problem in speech analysis and language translation. In *Proceedings of the 1961 International Conference on Machine Translation of Languages and Applied Language Analysis*, vol. 2, pp. 703-724.

Samuelsson, C. (1993). Morphological tagging based entirely on Bayesian inference. In *Proceedings of the 9th Nordic Conference on Computational Linguistics*, Stockholm University, Stockholm, Sweden.

Samuelsson, C.; Tapanainen, P.; Voutilainen, A. (1996). Inducing constraint grammars. In *Proceedings of the Third International Colloquium on Grammatical Inference.*

Samuelsson, C.; Voutilainen, A. (1997). Comparing a linguistic and a stochastic tagger. In *Proceedings of the 35th Annual Meeting of the Association for Computational Linguistics/8th Conference of the European Chapter of the Association for Computational Linguistics*, pp. 246-253.

Sánchez, F;, Porta, J.; Sancho, J.L.; Nieto, A.; Ballester, A.; Fernández, A.; Gómez, J.; Gómez, L.; Raigal, E.; Ruiz, R. (1999). La anotación de los corpus CREA y CORDE. *Revista de la Sociedad Española para el Procesamiento del Lenguaje Natural*, vol. 25 (Septiembre), pp. 175-182.

Schmid, H. (1994). Probabilistic part-of-speech tagging using decision trees. In *International Conference on New Methods in Language Processing*, pp. 44-49, Manchester (England).

Schütze, H.; Singer, Y. (1994). Part-of-speech tagging using a variable memory Markov model. In *Proceedings of the 32nd Annual Meeting of the Association for Computational Linguistics*, pp. 181-187.

Smeaton, A.F. (1992). Progress in the application of natural language processing to information retrieval tasks. *The Computer Jorunal*, vol. 35, pp. 268-278.

Stolcke, A.; Omohundro, S. (1993). Hidden Markov model induction by Bayesian model merging. In S.J. Hanson, J.D. Cowan and C. Lee Giles (eds.), *Advances in Neural Information Processing System*, vol. 5, pp. 11-18. Morgan Kaufmann, San Mateo, CA.

Stolcke, A.; Omohundro, S. (1994). Best-first model merging for hidden Markov model induction. *Technical Report* TR-94-003, International Computer Science Institute, University of California at Berkeley.

Stolz, W.S.; Tannenbaum, P.H.; Carstensen, F.V. (1965). A stochastic approach to the grammatical coding of English. *Communications of the ACM*, vol. 8, pp. 399-405.

Strzalkowski, T. (1995). Natural language information retrieval. *Information Processing & Management*, vol. 31, pp. 397-417.

Tapanainen, P.; Voutilainen, A. (1994). Tagging accurately - Don't guess if you know. In *Proceedings of the Fourth Conference on Applied Natural Language Processing*, Stuttgart.

Triviño Rodríguez, J.L. (1995). SEAM - Sistema experto para análisis morfológico. *Master's thesis*, Universidad de Málaga.

Triviño Rodríguez, J.L.; Morales Bueno, R. (2000). A Spanish POS tagger with variable memory. In *Proceedings of the Sixth International Workshop on Parsing Technologies (IWPT-2000)*, ACL/SIGPARSE, Trento (Italy), pp. 254-265.

Vilares Ferro, M.; Valderruten Vidal, A.; Graña Gil, J.; Alonso Pardo, M.A. (1995). Une approche formelle pour la gènération d'analyseurs de langages naturels. In P. Blache (ed.), *Proceedings of TALN'95*, Marseille (France), pp. 246-255.

Vilares Ferro, M.; Graña Gil, J.; Cacheda Seijo, F. (1996a). Verification of morphological analyzers. In *Proceedings of DIALOGUE'96*, Moscow (Russia), pp. 69-72.

Vilares Ferro, M.; Graña Gil, J.; Pan Bermúdez, A. (1996b). Building friendly architectures for tagging. *Revista de la Sociedad Española para el Procesamiento del Lenguaje Natural*, vol. 19 (Septiembre), pp. 127-132.

Vilares Ferro, M.; Graña Gil, J.; Alvariño Alvariño, P. (1997). Finite-state morphology and formal verification. In B.K. Boguraev, R. Garigliano, J.I. Tait and A. Kornai (eds.), *Journal of Natural Language Engineering, special issue on Extended Finite State of Language*, vol.2(4) (December), pp.303-304. Cambridge University Press.

Vilares Ferro, M.; Graña Gil, J.; Araujo, T.; Cabrero, D.; Diz, I. (1998). A tagger environment for Galician. In *Proceedings of Workshop on Language Resources for European Minority Languages*, Granada (Spain).

Viterbi, A.J. (1967). Error bounds for convolutional codes and an asymptotically optimal decoding algorithm. *IEEE Trans. Information Theory*, vol. IT-13 (April), pp. 260-269.

Voutilainen, A.; Heikkilä, J. (1994). An English constraint grammar (EngCG): a surface-syntactic parser of English. In Fries, Tottie and Schneider (eds.), *Creating and using English language corpora*. Rodopi.

Voutilainen, A. (1995). A syntax-based part-of-speech analyser. In *Proceedings of the 7th Conference of teh European Chapter of the Association for Computational Linguistics*, Dublin.

Weischedel, R.; Meteer, M.; Schwartz, R.; Ramshaw, L.; Palmucci, J. (1993). Coping with ambiguity and unknown through probabilistic models. *Computational Linguistics*, vol. 19, pp. 359-382.

Zavrel, J.; Daelemans, W. (1999). Recent advances in memory-based part-of-speech tagging. En *Actas del VI Simposio Internacional de Comunicación Social*, Centro de Lingüística Aplicada, Ministerio de Ciencia y Medio Ambiente, Santiago de Cuba, pp. 590-597.