

Desambiguación Verbal Automática

Un estudio sobre el rendimiento de la información
semántica argumental

Treball de final de grau

Autor: José Priego García

Director del treball: Irene Castellón Masalles

Tutor del curs: Carme Junyent Figueras

Grau de Lingüística

Facultat de Filologia

Universitat de Barcelona

Curs 2015-2016



UNIVERSITAT DE
BARCELONA

Desambiguación Verbal Automática: un estudio sobre el rendimiento de la información semántica argumental

José Priego García

Junio 2016

Resumen

Una de las tareas fundamentales todavía hoy pendientes de resolución en el ámbito del Procesamiento del Lenguaje Natural es la Desambiguación Semántica Automática (DSA); especialmente la tarea específica de Desambiguación Verbal Automática (DVA). En la presente investigación se aborda esta cuestión del modo siguiente: en primer lugar, se realiza una descripción del panorama actual en DSA, las aproximaciones posibles a esta tarea y los retos que plantea el desarrollo de la DVA. En segundo lugar, se lleva a cabo una tarea experimental con la finalidad de comprobar la viabilidad de una aproximación a la DVA basada en la información semántica de los argumentos verbales. Los buenos resultados obtenidos indicarían la necesidad de tener en cuenta este tipo de información en futuras propuestas de DVA.

Palabras clave: Semántica; Procesamiento del Lenguaje Natural; Desambiguación Verbal Automática; Aprendizaje Automático

Abstract

One of the key tasks still pending in the field of Natural Language Processing is Word Sense Disambiguation (WSD); especially the specific task of Verb Sense Disambiguation (VSD). In the present study this issue is addressed as follows: in the first place, a description of the current situation in WSD, the possible approaches to this task and the challenges posed by the development of VSD is provided. In the second place, an experimental task is performed in order to test the feasibility of an approach to VSD based on semantic information about verbal arguments. The good results obtained indicate the need to take into account this information in future proposals for VSD.

Keywords: Semantics; Natural Language Processing; Verb Sense Disambiguation; Machine Learning

Agradecimientos

A Irene Castellón por aceptar de buen grado la tarea de guiarme a lo largo de esta investigación, aconsejarme en los momentos de duda e indicarme pacientemente todas las correcciones necesarias.

A Carme Junyent por asesorarme sobre los aspectos formales relacionados con el proyecto y realizar su seguimiento.

A mi familia por el apoyo que me ha brindado a lo largo de toda la carrera y, especialmente, durante la elaboración de este trabajo final de grado.

A todos aquellos compañeros lingüistas que me han acompañado en el desarrollo de esta actividad y se han prestado a discutir todo tipo de dudas e inquietudes al respecto.

Finalmente, a todo lector potencial de esta obra por dedicar voluntariamente parte de su tiempo y atención a este primer intento de aportación a la investigación en lingüística.

Índice

0. Motivación	7
1. Introducción	9
2. Desambiguación Semántica Automática	11
2.1. Definición, características y aplicaciones	11
2.2. Aproximaciones a la DSA	12
2.2.1. Métodos basados en conocimiento	12
2.2.2. Métodos supervisados	14
2.2.3. Métodos no-supervisados	15
2.3. Particularidades de la Desambiguación Verbal Automática	16
3. Información semántica de los argumentos verbales en DVA	19
3.1. Justificación y objetivos de la investigación	19
3.2. Fuentes de información empleadas	20
3.3. Metodología experimental	22
3.4. Resultados obtenidos	25
3.4.1. <i>Baseline</i> e información morfológica y sintáctica	25
3.4.2. Papeles temáticos	27
3.4.3. Clasificación semántica	28
3.4.4. Aumentando el rendimiento de TCO	33
3.5. Discusión de los resultados	35
4. Conclusión	37
Referencias bibliográficas	39
Anexos	43

0. Motivación

Nunca en la historia de la humanidad se ha escrito tanto como en la actualidad. El desarrollo de las Tecnologías de la Información y la Comunicación en las últimas décadas no solo ha facilitado el intercambio de información entre personas sino que también ha incrementado el volumen de estos intercambios. Esta situación ha propiciado, entre otras, tanto la posibilidad de acercarse fácilmente a conocimiento antes inaccesible como la oportunidad de mejorar la visibilidad de lenguas y culturas hasta ahora excluidas por los medios de comunicación convencionales. En un escenario en el que cualquier usuario puede tener acceso a ingentes cantidades de información a través de internet, que se hallan principalmente en forma escrita, el Procesamiento del Lenguaje Natural (PLN) deviene un claro protagonista. Y no es sino mediante las aplicaciones que se desarrollan en este ámbito que podremos manejar de forma útil semejantes cantidades de información. Sin embargo, aplicaciones como la recuperación de información, la traducción automática o el resumen automático nunca llegarán a un nivel de verdadera eficiencia si no se resuelve antes el escollo de la ambigüedad inherente al lenguaje.

Así pues, enmarcada en este contexto, la presente investigación nace a partir de dos motivaciones principales: en primer lugar, realizar una primera incursión en la investigación en PLN acorde con mi interés personal por la Lingüística Computacional, la Semántica y la Inteligencia Artificial. En segundo lugar, producir mi propia y humilde aportación a una disciplina que, se espera, va a tener mucho que decir en los tiempos venideros.

Finalmente, me sentiría realmente satisfecho si esta investigación logra despertar en sus lectores la curiosidad y el interés por el PLN y sus aplicaciones.

1. Introducción

Una de las características intrínsecas del lenguaje y que se hace patente de forma diaria en la comunicación mediante cualquier lengua es su ambigüedad. Todas las lenguas del mundo poseen multitud de palabras polisémicas que pueden hacer referencia a diferentes sentidos en función del contexto de uso y resulta imprescindible saber identificar a cuál de ellos se está haciendo referencia en cada ocasión si se quiere comprender correctamente un mensaje. Por ejemplo, ante la oración “los participantes partieron la mañana del viernes” el hablante deberá identificar que el sentido activado por el verbo “partir” en esta ocasión es “abandonar un lugar” y no “fragmentar algo”. Este proceso de identificación del sentido activado por una palabra ambigua se conoce como desambiguación semántica y es llevado a cabo sin esfuerzo aparente por cualquier hablante durante su uso habitual del lenguaje, gracias al conocimiento del mundo y competencia lingüística desarrollados a lo largo de su vida. En el campo del Procesamiento del Lenguaje Natural (PLN), la disciplina que estudia el tratamiento automático del lenguaje de un modo computacional, la ambigüedad supone un verdadero obstáculo para el correcto desempeño de cualquier aplicación lingüística y es por ello que desde los inicios de la investigación en PLN se ha intentado emular la capacidad de desambiguación humana mediante el diseño de sistemas de Desambiguación Semántica Automática (DSA). Esta es una tarea que a día de hoy todavía no ha sido resuelta satisfactoriamente y es por ello que se ha generado, en torno a la DSA, un campo de investigación propio que da lugar a diferentes propuestas y aproximaciones en búsqueda de un mayor rendimiento.

La investigación que se presenta a continuación se encuentra dividida en dos secciones principales: en la primera sección se realizará una descripción de la DSA, sus características y aplicaciones principales así como las diferentes aproximaciones propuestas hasta la fecha. Se describirá también el caso concreto de la Desambiguación Verbal Automática (DVA); uno de los temas peor resueltos hasta el momento. En la segunda sección se propondrá y evaluará una aproximación a la DVA basada en información semántica de los argumentos verbales.

2. Desambiguación Semántica Automática

2.1. Definición, características y aplicaciones

A partir de lo que se ha señalado en la sección anterior, podría definirse la DSA como una tarea de clasificación: un programa informático (clasificador) debe asignar automáticamente a una determinada palabra uno de sus sentidos posibles (clases) en un contexto de uso concreto (Navigli, 2009; Pal y Saha, 2015). En tanto que trata de emular una capacidad cognitiva humana, la DSA es considerada una tarea propia del campo de la Inteligencia Artificial (IA) y, como el PLN en general, se la reconoce como un problema del tipo IA-Completo (Mallery, 1988); es decir, una tarea de las más complejas en el campo de la IA y que se halla al mismo nivel de dificultad que el desarrollo de la visión por ordenador o la improvisación ante situaciones inesperadas. Además de la complejidad de la tarea en sí, el desarrollo de la DSA cuenta con otras dificultades provenientes de dos ámbitos distintos: la diversidad metodológica y la obtención de información. En relación a la metodología, a la hora de llevar a cabo una tarea de DSA se debe establecer la procedencia de los sentidos, si serán extraídos de un diccionario o generados según el contexto, así como su número, si será un número de sentidos reducido de tipo amplio (*coarse-grained*) y consensuado o si será un elevado número fruto de distinciones finas entre sentidos (*fine-grained*). Así mismo, se debe establecer si la tarea será sensible al dominio textual y cuál será el objeto de desambiguación, si se trata de una única palabra por oración o de todas ellas a la vez. En segundo lugar, del mismo modo que el proceso de desambiguación que realizan los hablantes, una tarea de DSA depende completamente de la disponibilidad de conocimiento. A diferencia de una persona, una aplicación de software informático carece de un conocimiento del mundo y competencia lingüística propios, de modo que esta información tiene que ser provista de forma previa a la realización de la tarea. Como se detallará en la sección siguiente, una tarea de DSA puede basarse en la información contenida en un corpus, ya sea anotado o plano (no anotado), o bien en una base de datos estructurada como un lexicón computacional o una red semántica. Así pues, para llevar a cabo una tarea de DSA de forma productiva se necesita una gran cantidad de información y, si bien la obtención de un corpus plano de dimensiones considerables para una determinada lengua puede resultar relativamente sencilla, tanto la creación de un corpus anotado como la de una base de datos requieren de una gran cantidad de esfuerzo que se traduce en altos costes económicos y un largo tiempo de

desarrollo. Además, por si no fuera suficiente, estos recursos de elaboración manual requerirán actualizaciones siempre que tengan lugar cambios lingüísticos, se quiera aplicar la tarea a un dominio concreto o se altere el número de sentidos contemplados para cada palabra. Estas condiciones son la principal causa de la elevada dificultad para obtener cantidades de información suficientes a la hora de llevar a cabo una tarea de DSA (*data acquisition bottleneck*), de modo que esta escasez de información (*data sparseness*) afecta de forma negativa a los resultados. Un posible recurso para suavizar el efecto de la escasez de información podría ser la generalización de clases semánticas amplias con el fin de unificar sentidos similares de una misma palabra y así aumentar el número de ejemplos disponibles para estos en el corpus o la base de datos (Kohomban y Sun Lee, 2005; Abend et al., 2008). Así mismo, para tratar de reducir estos costes de elaboración se han desarrollado en los últimos años técnicas como el *bootstrapping* (Mihalcea, 2002), que permitiría la anotación automática de un corpus plano a partir de un corpus etiquetado de muestra, sistemas de anotación automática basados en herramientas de análisis lingüístico automático (Zhong y Tou, 2010) o propuestas para la actualización automática de bases de datos como WordNet (Cuadros, 2011).

Como puede suponerse a partir de lo explicado anteriormente, la DSA es una tarea intermedia; es decir, no se lleva a cabo por sí sola sino que sus resultados son empleados para mejorar la actuación de otras tareas relacionadas con el PLN como la traducción automática, la extracción y recuperación de información, el análisis de contenidos textuales o el desarrollo de la web semántica.

2.2. Aproximaciones a la DSA

Como se ha señalado anteriormente, las tareas de DSA requieren información suministrada de forma expresa y esta puede tomar diferentes formatos según la aproximación empleada. A continuación, se llevará a cabo una breve caracterización de las diferentes aproximaciones a la DSA existentes en la actualidad.

2.2.1. Métodos basados en conocimiento

Las aproximaciones a la DSA basadas en conocimiento se caracterizan por utilizar bases de datos estructuradas como fuente de información a partir de la cual deducir el sentido empleado por las palabras ambiguas en cada contexto. Entre los recursos empleados en este tipo de aproximaciones se encuentran los tesauros, los lexicones computacionales y las ontologías. De modo similar a como ocurrió en el desarrollo de la traducción

automática, los sistemas basados en conocimiento fueron los más empleados en las primeras tareas de DSA llevadas a cabo en la década de 1970. Se trata de una aproximación que ofrece buenos resultados en dominios específicos gracias al gran tamaño y riqueza informativa de las bases de datos pero que queda por detrás de los sistemas supervisados ante tareas de dominio libre. Pese a valerse de un mismo tipo de recurso, las diferentes propuestas difieren en el modo en que emplean la información proporcionada por una base de datos. Una de las primeras propuestas para la DSA a partir de conocimiento estructurado se basa en el grado de similitud (Lesk, 1986) entre la definición de los sentidos de la palabra a desambiguar con la de sus palabras vecinas (Patwardan et al., 2003). Según esta propuesta, es de esperar que la definición del sentido activado en un determinado contexto guarde una estrecha relación semántica con la de sus palabras vecinas. Pese a alcanzar unos buenos resultados para su época (entre un 50% y un 70% de aciertos), se trata de una propuesta demasiado sensible al número de palabras vecinas escogidas y al grado de detalle con el que la base de datos las defina. Es por ello que se han desarrollado otras propuestas como las basadas en preferencias de selección (Del Corro et al., 2014). En esta aproximación el sistema de DSA parte de la idea de que cada posible sentido de una palabra cuenta con una serie de preferencias sobre los rasgos semánticos de las palabras con las que establecerá relaciones sintácticas. Estas preferencias deben constar en la base de datos empleada y se reflejan en la frecuencia de coaparición de dos palabras en cualquier texto real. Finalmente, destacan también otras dos propuestas que se sirven de información semántica: los sistemas basados en medidas de similitud semántica y los basados en grafos. En los primeros la desambiguación radica en el resultado del cálculo de la distancia semántica entre los sentidos de las palabras que coocurren (Mihalcea y Moldovan, 1998; Tsatsaronis et al., 2008). Según esta propuesta, se considerará acertado aquél sentido que se halle a una menor distancia semántica de sus palabras vecinas. La segunda propuesta, en cambio, recurre a la noción de cadena léxica (Halliday y Hasan, 1976) para establecer relaciones de tipo semántico no entre palabras, como en la ocasión anterior, sino entre las características del contexto y los diferentes sentidos de la palabra a desambiguar (Alexopoulou et al., 2009; Kasture y Agrawal, 2012).

2.2.2. Métodos supervisados

Desde los inicios de la década de 1990 se ha podido observar un cierto cambio de tendencia en los sistemas de DSA que ha dejado de lado las aproximaciones basadas en conocimiento estructurado por aquellas de tipo supervisado o basadas en corpus etiquetados. Estas aproximaciones emplean técnicas de aprendizaje automático para realizar la desambiguación de los términos contenidos en un corpus de evaluación: la información explicitada en el corpus etiquetado manualmente se ofrece como base para el entrenamiento de un clasificador, un programa informático, el cual asignará un sentido o clase a cada palabra a desambiguar en función de las generalizaciones que ha extraído en el proceso de entrenamiento. Las tareas de desambiguación basadas en esta aproximación acostumbran a centrarse en una única palabra por oración, de modo que el corpus de aprendizaje cuenta con un gran número de oraciones en las que, además del sentido de dicha palabra en el contexto actual, se etiquetan diferentes tipos de información a partir de los cuales extraer las características que determinarían cada sentido. De entre los diferentes tipos de información que pueden etiquetarse en un corpus, cabe destacar que la práctica totalidad de las investigaciones en DSA que siguen esta aproximación emplean tanto la categoría morfológica de las diferentes palabras del texto como la función sintáctica que desempeñan en la oración a la que pertenecen. Así mismo, la mayoría de las propuestas acostumbran a incluir también el lema de las palabras circundantes al término a desambiguar en una ventana que suele situarse en unas tres unidades previas y posteriores a esta. Podría considerarse, pues, que esta es la información base a partir de la cual llevar a cabo una tarea de DSA de tipo supervisado. Tomando como referencia esta configuración de partida se han desarrollado diferentes propuestas que añaden otros tipos de información con la finalidad de tratar de mejorar los resultados en este tipo de tareas: recursos de tipo léxico como las *named entities* (Dang y Palmer, 2005), de tipo sintáctico como las colocaciones (Zhong y Tou, 2010) o de tipo semántico como los hiperónimos de cada término (Buscaldi et al., 2006; Dang y Palmer, 2005), las preferencias de selección de cada verbo (Abend et al., 2008) o los *synsets* de WordNet de cada palabra (Kohomban y Sun Lee, 2005). Así mismo, existen también propuestas que emplean información sobre el dominio o temática general del texto (Dang y Palmer, 2005) o que exploran la creación de nuevas categorías basadas en relaciones sintáctico-semánticas (*dynamic dependency neighbours* en Dligach y Palmer, 2008).

Otra de las características relevantes de los sistemas de desambiguación supervisados es el empleo de algoritmos de clasificación: el proceso de aprendizaje y clasificación llevado a cabo por el clasificador está siempre regido por un determinado algoritmo que indica las reglas o pasos a seguir. En la actualidad existe una gran diversidad de algoritmos que han sido aplicados a tareas de DSA. Entre los más destacados se encuentran las listas de decisión, los árboles de decisión (C4.5), los de tipo probabilístico (Naive Bayes), los basados en instancias (k-Nearest Neighbor), las redes neurales y los basados en *support vector machines* (Sequential Minimal Optimization). Así mismo, se han realizado propuestas basadas en el uso simultáneo de diversos algoritmos y la posterior obtención de resultados a partir del consenso general entre estos (AdaBoost).

Los sistemas supervisados son más versátiles que los basados en conocimiento y son además los que otorgan un mayor porcentaje de palabras correctamente desambiguadas a día de hoy. Sin embargo, su mayor contrapartida es el hecho de que el proceso de etiquetaje manual incrementa mucho su coste de elaboración. Este es un efecto que aumenta todavía más si se tiene en cuenta que se necesita un corpus de elevadas dimensiones, que contenga un gran número de oraciones, si se quiere minimizar el problema de la *data sparseness*.

2.2.3. Métodos no-supervisados

Como se ha señalado anteriormente, la creación de los recursos informativos necesarios para llevar a cabo una tarea de DSA tiene un alto coste tanto económico como de tiempo de desarrollo. Es por ello que en los años recientes se ha optado por el desarrollo de lo que se conoce como sistemas de DSA no-supervisados que se basan en cálculos estadísticos a partir de corpus lingüísticos planos. Estos sistemas parten de la idea de que un determinado sentido de cierta palabra siempre se hallará en presencia de palabras similares; es decir, se encontrará en un contexto lingüístico similar. De este modo, se inducen los diferentes sentidos de cada palabra a partir de un proceso de agrupación automática (*clustering*) de estas en función de su contexto de aparición y, posteriormente, se clasifica cada ocurrencia de una determinada palabra en uno de estos grupos o clases. La mayor ventaja de estos sistemas es que basan el proceso de desambiguación en corpus planos de grandes dimensiones, algo fácil de obtener hoy en día, y, por lo tanto, permiten ahorrarse el laborioso proceso de etiquetaje manual. Sin embargo, esta es también su mayor desventaja: a diferencia de las otras dos

aproximaciones antes descritas, la no-supervisada no utiliza sentidos previamente establecidos y consensuados entre diferentes fuentes de información sino que los induce a partir del corpus suministrado y, por lo tanto, el resultado de sus desambiguaciones no se corresponde con el de otras aproximaciones. Es por ello que estos sistemas requieren de un posterior proceso de revisión manual para valorar los sentidos inducidos para cada palabra y las clasificaciones realizadas. Entre las diferentes propuestas inspiradas en el modelo no-supervisado destacan dos tipos principales: aquellas basadas en vectores contextuales (Savova et al., 2005) y aquellas basadas en *clustering* de palabras (Wang et al., 2013; Lin y Verspoor, 2008). La primera opción representa el contexto de cada ocurrencia de una determinada palabra mediante vectores espaciales para posteriormente comparar su similitud con el del resto de ocurrencias y determinar así las clases o sentidos a partir de su ángulo de proximidad. La segunda propuesta, en cambio, realiza un proceso de *clustering* a partir de la similitud entre las palabras vecinas de cada ocurrencia de una determinada palabra.

2.3. Particularidades de la Desambiguación Verbal Automática

En las secciones anteriores se ha presentado qué es la DSA así como las diferentes aproximaciones posibles a este tipo de tareas. Del mismo modo que a la hora de llevar a cabo una tarea de DSA se puede escoger si el objeto a desambiguar serán todas las palabras del texto o únicamente una de ellas, también es posible centrar el objeto de desambiguación en una única categoría morfológica como, por ejemplo, el verbo. Precisamente la desambiguación verbal ha devenido una de las principales áreas de interés y desarrollo de la DSA en los últimos años, dando lugar a la creación de sistemas específicos de DVA. Este creciente interés por la desambiguación verbal responde a dos motivos principales: los escasos resultados conseguidos hasta la fecha y el papel central del verbo en la estructura oracional. Comenzando por el primero de ellos, en la actualidad los mejores resultados obtenidos en una tarea de desambiguación verbal son de un 82% de verbos correctamente desambiguados (Del Corro et al., 2014). Se trata de unos resultados que todavía se hallan lejos de lo deseable en este tipo de tareas al dejar todavía un considerable margen de error y que, por lo tanto, invitan a una mayor investigación con el fin de mejorarlos. Esta necesidad de mejora se corrobora si se tiene en cuenta, como se señalaba anteriormente, el papel relevante del verbo dentro de la estructura oracional como núcleo del predicado y administrador de los constituyentes de la oración mediante la selección de argumentos así como la adjudicación de funciones

sintácticas y papeles temáticos. Así pues, debido a su centralidad, una mejora en la desambiguación verbal podría suponer de forma colateral una mejora en aquellas tareas de DSA en las que se pretenda desambiguar todas las palabras de un texto. Así mismo, una mejora en los resultados de las tareas generales de DSA contribuiría de forma positiva al desarrollo y productividad de otras tareas relacionadas con el PLN tal y como se ha señalado en secciones anteriores. A partir de lo recientemente expuesto no resulta complicado entender por qué la DVA se ha convertido en los últimos años en un objeto de investigación relevante tanto en el campo de la DSA como en el del PLN en general.

3. Información semántica de los argumentos verbales en la DVA

3.1. Justificación y objetivos de la investigación

El panorama descrito en la sección anterior ha dejado patente que las investigaciones previas en el campo de la DSA de corte general se han limitado a emplear una serie de recursos concretos; mayoritariamente información acerca de la categoría morfológica y función sintáctica de las palabras próximas al término a desambiguar. Además, se ha señalado también cómo la aplicación de estos recursos a tareas específicas de DVA no ha reportado hasta la fecha unos resultados tan buenos como se podría desear (Buscaldi et al., 2006). Ante esta situación resulta evidente la necesidad de explorar nuevas fuentes de información relacionadas con el verbo que contribuyan a mejorar el rendimiento de las tareas de DVA y, en definitiva, el campo de la DSA en su conjunto. Como se señalaba en la sección anterior, una característica intrínseca del verbo que no ha recibido la atención merecida hasta tiempos recientes es la estrecha relación sintáctico-semántica que este establece con sus diferentes argumentos; una relación que puede condicionar la tipología de los argumentos en función del sentido activado por el verbo en un contexto de uso determinado. Puede suponerse, pues, que el rendimiento de las tareas de DVA podría aumentar si se contemplara en ellas información relativa a esta relación verbo-argumento; especialmente si, además de información morfológica y sintáctica, se contara también con información de tipo semántico. Esta necesidad de explotar la información argumental en el campo de la DVA ya ha sido señalada por recientes investigaciones que la incluyen de diversas formas en sus diseños experimentales; ya sea mediante la abstracción automática de preferencias de selección (Ye y Baldwin, 2006), el análisis estadístico y *clustering* de parejas verbo-argumento (Wagner et al., 2009) o mediante la inclusión de información semántica acerca de los argumentos verbales en un corpus anotado (Dang y Palmer, 2005; Dligach y Palmer, 2008).

A partir de lo anteriormente expuesto podrían justificarse las dos hipótesis de partida de esta investigación: en primer lugar, que los bajos resultados obtenidos hasta la fecha en el campo de la DVA podrían deberse a planteamientos generalistas que no tienen en cuenta características propias del verbo como es, por ejemplo, su relación con los argumentos verbales. En segundo lugar, que la información semántica de estos argumentos podría resultar útil a la hora de llevar a cabo una tarea de naturaleza semántica como es la DVA. Con la finalidad de comprobar estas hipótesis, y siguiendo

la tendencia iniciada por las investigaciones anteriormente citadas, en la presente investigación se llevará a cabo una tarea experimental mediante la cual se pretende evaluar el rendimiento de diferentes tipos de información semántica sobre los argumentos verbales en el proceso de DSA de una serie de verbos.

Dicha tarea experimental será expuesta en las próximas secciones del modo siguiente: en primer lugar, se detallarán los tipos de información empleados (sección 3.2). A continuación, se justificará y describirá la metodología experimental (sección 3.3). Posteriormente, se presentarán los diferentes experimentos realizados, las configuraciones de información empleadas en cada uno de ellos y los resultados obtenidos (sección 3.4). Finalmente, en la última sección se discutirá el valor de estos resultados y sus implicaciones en relación a las hipótesis antes planteadas (sección 3.5)

3.2. Fuentes de información empleadas

Debido a que el objetivo final de esta tarea es la evaluación del rendimiento de diversos tipos de información lingüística procedentes de diferentes fuentes, se ha considerado necesario adoptar una aproximación a la DVA de tipo supervisado. Como ya se ha apuntado anteriormente, la aproximación supervisada permite conocer de antemano los datos que conforman la muestra; en este caso, las características de los argumentos de cada verbo y el sentido activado por este en cada oración. De este modo, la aproximación supervisada otorga la posibilidad de realizar diferentes combinaciones informativas según se requiera en cada experimento.

La presente investigación toma como muestra un corpus anotado compilado expresamente para la ocasión a partir del corpus SenseM (Alonso et al., 2007; Fernández & Vazquez, 2014), que posteriormente ha sido ampliado con información semántica sobre los argumentos verbales de cada una de las oraciones a partir de EuroWordNet (Castellón et al., 2012). El corpus empleado cuenta con un total de 1.033 oraciones correspondientes a 12 verbos; lo que supone entre 65 y 105 oraciones por cada uno de los verbos escogidos (consultar anexo 1 para ver una descripción detallada del corpus). Con la finalidad de poder contrastar posteriormente el efecto del número de sentidos¹ en una tarea de DVA, los verbos escogidos para la elaboración del corpus

¹ Se ha limitado el nivel de granularidad a un máximo de cinco sentidos con la finalidad de recoger únicamente aquellos sentidos que gozan de mayor consenso entre las distintas fuentes disponibles. A medida que aumenta el nivel de detalle en la distinción entre sentidos y, por lo tanto, su número es más probable hallar discrepancias entre diferentes corpus, bases de datos y diccionarios.

empleado se hallan en un rango de entre dos hasta cinco sentidos, con tres verbos distintos para cada nivel de granularidad o detalle en la distinción de sentidos. Para lograr una mayor fiabilidad de los resultados se ha procurado, además, que ninguno de los sentidos recogidos en el corpus para cada verbo estuviera infrarrepresentado; es decir, ninguno de ellos cuenta con menos de un tercio de los ejemplos que le corresponderían en un reparto equitativo de los diferentes sentidos entre el total de oraciones recogidas para un determinado verbo. De este modo, se ha procurado minimizar las inevitables diferencias en la presencia de determinados sentidos de un mismo verbo debido a su frecuencia de aparición en el corpus. Por poner un caso concreto, el verbo “hallar” cuenta con cuatro sentidos diferentes en este corpus y un total de 94 oraciones: 34 para el primer sentido (36% del total), 9 para el segundo (10%), 29 para el tercero (31%) y 22 para el cuarto (23%). Así pues, el sentido con menor representación cuenta con algo más del tercio de lo que le correspondería en un reparto equitativo (25% de las oraciones). Al tratarse de un corpus anotado, las diferentes oraciones que lo componen contienen información relativa a diferentes niveles de análisis lingüístico. A nivel léxico, cada una ha sido etiquetada con el lema correspondiente a su verbo principal; verbo que es, además, el candidato a desambiguar. Así mismo, cada oración cuenta con el sentido específico que toma dicho verbo en ese caso concreto. Siguiendo el ejemplo de investigaciones anteriores, cada oración recoge también información acerca de la categoría morfológica y función sintáctica de cada uno de los argumentos verbales. En lo tocante al nivel semántico, el realmente relevante en esta tarea, los argumentos de cada oración han sido etiquetados según su papel temático y según su clasificación en tres ontologías de uso común en el ámbito del PLN: la Suggested Upper Merged Ontology (Pease et al., 2002), los Supersenses de WordNet (Fellbaum, 2005) y la Top Concept Ontology (Álvez et al., 2008). Mientras que la clasificación de roles temáticos establecida en el corpus Sensem cuenta con tan solo una veintena de categorías, la complejidad de las ontologías semánticas es notablemente mayor. A continuación, se presenta una breve caracterización de estas.

Suggested Upper Merged Ontology

Suggested Upper Merged Ontology (SUMO) aparece el año 2001 como resultado de la unificación de diversas ontologías con la finalidad de crear un recurso útil para futuras tareas de PLN. Es precisamente por este motivo que, como las otras dos ontologías a las que se hace mención en este estudio, se encuentra enlazada con WordNet. SUMO

cuenta con un total de 2.302 categorías distintas, de modo que permite una alta capacidad de especificación a la hora de representar diferentes términos. Quedará por demostrar en las próximas secciones si esta alta especificidad resulta de utilidad en una tarea de DVA.

Supersenses

Originalmente concebidos para la clasificación en campos semánticos de términos en lengua inglesa, los Supersenses de WordNet ofrecen información sobre la categoría morfológica de una palabra y su atributo semántico más característico. Los Supersenses están formados por 25 etiquetas específicas para sustantivos y 15 para verbos, de modo que ofrecen una capacidad de generalización mucho mayor que SUMO y, por lo tanto, permiten relacionar muchos más términos que compartan una determinada categoría. Así pues, el empleo de esta clasificación servirá para poner a prueba si una clasificación de tipo generalista resulta útil para mejorar los resultados en DVA.

Top Concept Ontology

Top Concept Ontology (TCO) fue concebida originalmente como un medio para posibilitar el *clustering* y la comparación de términos entre las plataformas de WordNet de diferentes idiomas. Cuenta con un total de 63 categorías jerárquicamente distribuidas que en su nivel más alto permiten diferenciar entre objetos físicos (1st Order Entity), situaciones (2nd Order Entity) y entidades no observables (3rd Order Entity); niveles que a su vez contienen otras clasificaciones internas. Cuenta además con la particularidad de que una misma entidad puede ser descrita mediante el uso de diferentes categorías a la vez. TCO permite de este modo una alta capacidad para definir con detalle las características de cada término mediante la adición de categorías, a la vez que posibilita el establecimiento de relaciones entre diferentes términos a partir del contraste de categorías compartidas. Así pues, puede considerarse que se encuentra en un punto medio entre las capacidades anteriormente otorgadas a SUMO y los Supersenses; cosa que debería reflejarse posteriormente en las tareas de DVA en las que TCO tenga un papel relevante.

3.3. Metodología experimental

Una vez descritas las características del corpus empleado en la presente investigación se procederá a describir la metodología seguida en esta. Como se ha señalado anteriormente, la DSA se puede definir básicamente como una tarea de clasificación. En

dicha tarea un programa informático que actúa a modo de clasificador toma como ejemplo las instancias recogidas un corpus de entrenamiento, establece relaciones a partir de este mediante un proceso de aprendizaje basado en un determinado algoritmo y, finalmente, propone una clasificación para las instancias contenidas en un corpus de evaluación en el que estas carecen de un valor para el atributo que se pretende averiguar. En el caso concreto de esta investigación, el clasificador toma como ejemplo las oraciones contenidas en el corpus anteriormente descrito y, tras abstraer durante el aprendizaje aquellas características que los definen, otorga el sentido más probable, dentro de los posibles, para cada verbo de las diferentes oraciones existentes en el corpus de evaluación.

Los diferentes experimentos se han llevado a cabo mediante la plataforma de software para la minería de datos y el aprendizaje automático Weka (Witten et al., 2011), desarrollada por la Universidad de Waikato (Nueva Zelanda). Para ello se ha tenido que adaptar la información contenida en el corpus anotado a un formato específico capaz de ser procesado por esta aplicación. Tras esta adaptación cada una de las oraciones ha sido transformada en una instancia que presenta un determinado valor para cada uno de los atributos anteriormente descritos.

Superar, NP, Direct obj., T, TimeDuration, noun.time, 3rdOrderEntity_Quantity_Time, 1-Vencer a alguien o algo en una prueba

Figura 1 – Instancia para el verbo “superar” en la que se indican, respectivamente, las siguientes informaciones: lema del verbo, categoría morfológica, función sintáctica, papel temático, SUMO, Supersense, TCO y sentido verbal.

Como se puede observar en la figura 1, el formato exigido por Weka permite introducir valores de tipo nominal pero, sin embargo, limita la expresión de información a un único valor por atributo. Esta característica, que no supone un inconveniente de entrada, será recuperada y valorada más adelante (sección 3.4.4).

Para obtener el corpus de evaluación necesario para llevar a cabo una tarea de tipo supervisado se ha utilizado un proceso de *10-fold cross validation*. Mediante este sistema, en el inicio de cada tarea el clasificador divide automáticamente el corpus de aprendizaje suministrado en diez fragmentos proporcionales para posteriormente emplear una de estas divisiones como corpus de evaluación, eliminando el valor de cada instancia para el atributo que se pretende clasificar, y manteniendo el resto de particiones como corpus de aprendizaje. Este procedimiento tiene lugar diez veces consecutivas, tomando en cada ocasión como corpus de evaluación una partición

distinta de las diez generadas previamente, y el resultado final se obtiene realizando una media de los resultados individuales.

Como se ha comentado en la presentación de las aproximaciones supervisadas, todas las tareas de clasificación deben seguir un determinado patrón o norma que rija en qué principios debe basarse dicha clasificación y mediante qué proceso debe tener lugar. En el caso de esta investigación se ha considerado oportuno el uso de un patrón o algoritmo de clasificación basado en el principio de *support vector machines* (SVM); concretamente, el algoritmo Sequential Minimal Optimization (Platt, 1998). Dicho algoritmo funciona del siguiente modo: en primer lugar, escoge dos valores posibles del atributo a clasificar y representa las diferentes instancias del corpus de aprendizaje que presentan dichos valores como puntos en un plano espacial. A continuación, halla aquellos dos ejemplos que se encuentran más alejados de sus compañeros de clase y, a la vez, más próximos al grupo contrario; los puntos que representan dichas instancias serán denominados vectores de soporte. A partir de estos vectores se crea un hiperplano con la intención de separar con la mayor eficiencia posible las secciones del espacio ocupadas por cada uno de ambos valores. Una vez se ha generado este hiperplano, se procede a representar las instancias pendientes de clasificación pertenecientes al corpus de evaluación y se les otorga un valor para el atributo a clasificar en función del lado del hiperplano en el que se encuentren (figura 2).




Figura 2 - Representación de un plano y el hiperplano generado a partir de los vectores de soporte. Se puede ver con claridad cómo el hiperplano separa eficientemente los dos valores de un determinado atributo (Witten et al., 2011).

Debido a sus características, un algoritmo basado en vectores de soporte se encuentra limitado a realizar clasificaciones binarias; es decir, solo puede realizar una clasificación entre dos valores distintos para un mismo atributo. De este modo, en la

investigación presente, el algoritmo creará un único plano durante la clasificación de verbos con dos sentidos, pero deberá realizar $n+(n-2)$ planos distintos cuando el verbo a desambiguar presente un mayor número de sentidos (n) con tal de realizar todas las combinaciones entre los valores existentes para, posteriormente, emitir un único resultado de clasificación a partir de estos. No obstante esta particularidad, los algoritmos basados en SVM presentan mejores resultados que otros algoritmos típicamente empleados en DSA como pueden ser los de tipo probabilístico bayesianos como Naive Bayes o los basados en instancias vecinas como k-Nearest Neighbor (Escudero, 2006; Witten et al., 2011). En comparación con estos últimos presentan, además, una clara ventaja en tanto que no son susceptibles a posibles desviaciones causadas por diferencias en el número de instancias contenidas en cada grupo al basarse únicamente en aquellas dos que actúan como vectores de soporte.

3.4. Resultados obtenidos

Tras presentar el diseño y características de la tarea experimental, se realizará a continuación una descripción detallada de los resultados obtenidos en esta. En primer lugar, se establecerán como punto de referencia los resultados obtenidos mediante el cálculo de la *baseline* así como los resultados de una clasificación basada únicamente en los atributos de categoría morfológica y función sintáctica. En segundo lugar, se llevará a cabo una serie de experimentos bajo diferentes configuraciones de los atributos semánticos anteriormente descritos. En todo momento se analizarán en primer lugar los resultados obtenidos en las pruebas realizadas de forma individual para cada verbo y en segundo lugar los resultados pertenecientes a aquella prueba realizada con el corpus completo.

3.4.1. Baseline e información morfológica y sintáctica

El cálculo de la *baseline*² es el primer paso que se debe llevar a cabo si se quiere evaluar el rendimiento de diferentes fuentes de información en cualquier tipo de tarea de clasificación. La *baseline* de cada verbo se ha obtenido siguiendo el proceso de clasificación *most frequent sense*, en el cual se asigna el valor predominante para el atributo “sentido” en todas las instancias pertenecientes a cada uno de los verbos presentes en el corpus. Los cálculos se han llevado a cabo mediante ZeroR, un

² Se entiende por *baseline* aquél resultado que sirve como referencia para medir el rendimiento de las diferentes configuraciones informativas empleadas en tareas posteriores. Es por ello que en esta ocasión se ha calculado a partir de una clasificación tan simple como la atribución del sentido más común de cada verbo.

algoritmo que permite el cálculo de la *baseline* de forma automática y que se halla implementado en Weka. Los resultados individuales obtenidos (tabla 1) distan de ser aceptables para una tarea de este tipo puesto que en el mejor de los casos llegan a un 61,8% de instancias correctamente clasificadas y en el peor de ellos se encuentran en un mero 32,3%. En cuanto a la *baseline* obtenida con el corpus completo, se puede observar que esta se halla en un punto medio entre las individuales (52,17%).

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Superar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
<i>Baseline</i>	61.85	64.63	65.048	52.32	48.35	41.97	36.17	41.75	76.82	40.65	60	32.30	52.17

Tabla 1 - Resultados del cálculo de la *baseline*.

A continuación, se procederá a analizar los resultados obtenidos mediante el empleo de la información sobre categoría morfológica y función sintáctica de los argumentos verbales (tabla 2). A nivel individual salta a la vista que dos de los verbos utilizados responden excepcionalmente bien a estas informaciones (97 puntos). Sin embargo, estos no pueden considerarse como representativos si se comparan con el resto; que se encuentran alrededor de los 60 puntos, con excepciones de 89,5 puntos en el mejor caso y 39,5 en el peor de ellos. Al emplear el corpus completo se han obtenido unos resultados del orden de 70 puntos.

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Superar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
MS	97.93	63.41	66.01	89.53	75.82	39.50	59.57	59.34	97.56	59.34	72.85	52.30	70.18

Tabla 2- Resultados de la clasificación basada en información morfológica y sintáctica (MS).

El hecho de que la desambiguación de determinados verbos como “beneficiar” y “tratar” logre unos resultados tan buenos únicamente con este tipo de información probablemente se deba a la existencia de unas fuertes preferencias de tipo morfológico-sintáctico, según las cuales cada uno de los sentidos determina claramente la tipología a la que deben ajustarse sus posibles argumentos. Por ejemplo, en el caso de “beneficiar” se distinguen dos sentidos: “ser de ayuda a alguien o algo” (sentido 1) y “mejorar lo personal aprovechándose de algo” (sentido 2). Si se consultan las diferentes instancias del corpus para este verbo, se puede comprobar que mientras que en el primer sentido predominan los argumentos verbales con papel temático “destino” y función de objeto directo expresados en forma de sintagma preposicional introducido por la preposición

“a” (“la globalización beneficia a los fuertes”), en el segundo sentido se observa en todas las instancias una clara preferencia por argumentos con papel temático “tema” y función de complemento de régimen verbal en forma de sintagma preposicional introducido por la preposición “de” (“varias empresas privadas se beneficiaron de esos préstamos”).

La comparación de los resultados obtenidos en esta tarea con aquellos conseguidos durante el cálculo de la *baseline* permite apreciar una mejora en todos los casos que, aunque claramente positiva, no es suficiente para sustentar el correcto desempeño de una aplicación de DVA. Estos resultados ratifican, como se exponía anteriormente, la necesidad de explorar nuevas fuentes de información como las que se evaluarán a continuación.

3.4.2. Papeles temáticos

Tras detallar los resultados obtenidos en las pruebas preliminares, que servirán de referencia para medir los resultados de los próximos experimentos, se procederá a continuación a exponer aquellos obtenidos a partir del empleo de información semántica.

En primer lugar, se ha recuperado la última configuración basada en información morfológica y sintáctica para enriquecerla, en esta ocasión, con el atributo correspondiente a los papeles temáticos representados por cada uno de los argumentos del verbo a desambiguar. Como se puede ver en la tabla que se presenta a continuación (tabla 3), la inclusión de los papeles temáticos incrementa de forma considerable el porcentaje de verbos correctamente desambiguados. En esta ocasión los resultados obtenidos se hallan entre los 60 y 97,6 puntos en las tareas individuales y alcanzan los 87,7 puntos en la tarea conjunta.

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Superar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
PTs + MS	96.90	95.12	76.69	97.67	76.92	98.76	89.36	95.60	97.56	73.62	88.57	60	87.70
PTs	96.90	95.12	80.58	96.51	79.12	98.76	89.36	95.60	97.56	80.21	84.28	67.69	89.25

Tabla 3- Resultados de la clasificación efectuada con información sobre papeles temáticos e información morfológico-sintáctica (PTs+MS) y de la clasificación basada únicamente en papeles temáticos (PTs). Los mejores resultados de cada verbo se hallan indicados en negrita.

Por otro lado, puede resultar interesante observar la variación en los resultados anteriores si se lleva a cabo la misma prueba retirando esta vez la información acerca de la categoría morfológica y la función sintáctica de los argumentos; es decir, si se lleva a cabo una clasificación tomando como único atributo los papeles temáticos. Como se muestra en la tabla 3, puede comprobarse que los resultados no solo se mantienen (salvo en dos ocasiones, verbos “detener” y “actuar”, en las que se llega a perder entre 1 y 4 puntos) sino que en la mayoría de verbos se observan mejoras de hasta 7 puntos. También se observa una ligera mejora en la prueba realizada con el corpus completo que en esta ocasión alcanza los 1,5 puntos.

A continuación, en el gráfico 1, se contrastan los resultados obtenidos hasta el momento a partir del cálculo de la *baseline* así como en las pruebas basadas en información morfológica y sintáctica o con información sobre papeles temáticos.

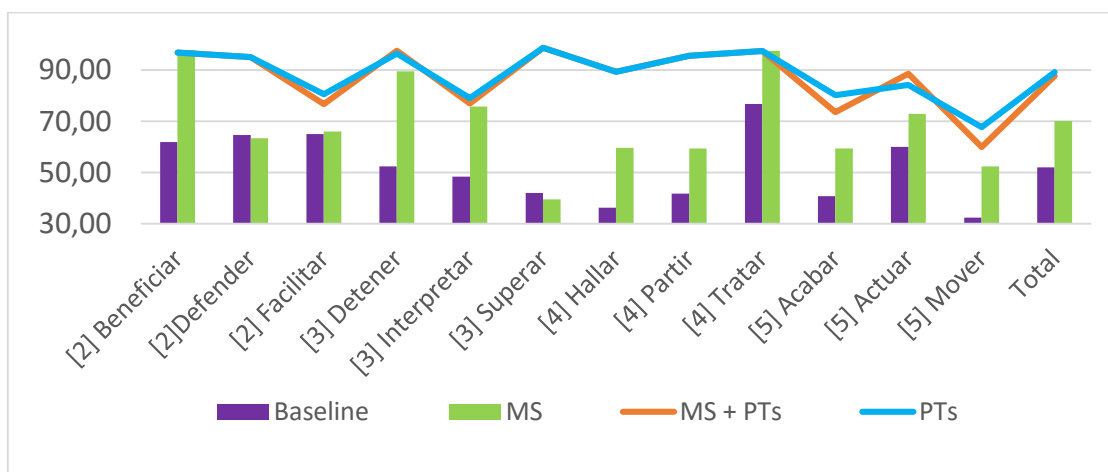


Gráfico 1 – Resultados obtenidos mediante el cálculo de la *baseline* y en las clasificaciones basadas en información morfológica y sintáctica (MS); morfológica, sintáctica y sobre papeles temáticos (MS+PTs); y únicamente sobre papeles temáticos (PTs).

3.4.3. Clasificación semántica

En esta sección se tratará de comprobar hasta qué punto la información semántica de los diferentes argumentos verbales, expresada según la clasificación de diversas ontologías, puede ayudar a mejorar los resultados obtenidos anteriormente o si bien puede incluso llegar a sustentar una aplicación de DVA por sí sola.

En primer lugar, se examinarán las variaciones en el rendimiento que se derivan de incluir al unísono la información proporcionada por las tres ontologías consideradas en esta investigación: SUMO, Supersenses de WordNet y TCO.

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Superar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
MS+PTs	96.90	95.12	76.69	97.67	76.92	98.76	89.36	95.60	97.56	73.62	88.57	60	87.70
Ont+MS+PTs	96.90	89.02	85.43	93.02	83.51	98.76	90.42	94.50	97.56	75.82	87.14	70.76	88.28
Ont+PTs	90.72	90.24	88.34	94.18	83.51	97.53	89.36	93.40	97.56	78.02	80	69.23	88.67
Ont+MS	96.90	60.97	75.72	86.04	81.31	33.33	75.53	62.63	97.56	61.53	72.85	58.46	72.02
Ont	56.70	58.53	74.75	47.67	70.32	37.03	39.36	54.94	71.95	37.36	58.57	44.61	55.66

Tabla 4 – Resultados de la clasificación basada en información morfológica, sintáctica y sobre papeles temáticos (MS+PTs) así como de las clasificaciones basadas en las 3 ontologías con información morfológico-sintáctica y papeles temáticos (Ont+MS+PTs); únicamente con papeles temáticos (Ont+PTs); únicamente con información morfológico-sintáctica (Ont+MS); y sin información adicional (Ont).

Como se puede ver en la tabla 4, la adición simultánea de la información proporcionada por las tres ontologías produce resultados heterogéneos si se aplica a la configuración anterior basada en información morfológico-sintáctica y papeles temáticos. Si se contrasta el resultado de ambas pruebas puede comprobarse que en la mayoría de casos el resultado se mantiene o incluso puede llegar a mejorar hasta 10 puntos mientras que en tan solo tres ocasiones (verbos “defender”, “detener” y “partir”) puede llegar a descender en 6 puntos. Este discreto descenso de los resultados podría deberse a la existencia de las claras diferencias antes señaladas entre las tres ontologías empleadas; no solo en cuanto al número de categorías sino también a la naturaleza de estas. Por otro lado, en la prueba realizada con el corpus completo se detecta una ligera mejora de 0,5 puntos al incluir la información extraída de las ontologías.

Como sucedía en la clasificación basada en papeles temáticos, los resultados de determinados verbos pueden mejorar levemente si se sustrae la información morfológica y sintáctica mientras que otros pueden empeorar ligeramente (especialmente los verbos “beneficiar” y “actuar”). En cuanto a la prueba de esta configuración con el corpus completo se obtiene una mejora de 0,4 puntos respecto de la realizada con ayuda de información morfológica y sintáctica. Del mismo modo, puede resultar interesante también realizar la misma prueba sustrayendo esta vez el apoyo de la información sobre papeles temáticos e incluyendo la de tipo morfológico-sintáctico. Si se realiza una nueva clasificación en estas condiciones se puede observar que el rendimiento decae de forma acusada cuando la información sobre ontologías no cuenta con el apoyo de los papeles temáticos: con la única ayuda de la información morfológico-sintáctica la mayoría de los verbos padecen caídas de entre 2 y 32 puntos respecto a la tarea anterior (con una caída excepcional de 65 puntos en el verbo “superar”) mientras que al emplear

el corpus completo se registra una caída de 16 puntos. En último lugar, si se reutiliza la última configuración sustrayendo esta vez también la información morfológico-sintáctica se puede deducir a partir de los resultados obtenidos que la DVA basada únicamente en la combinación de estas tres ontologías resulta inviable: en ninguno de los casos se logra mantener el resultado de pruebas anteriores y los resultados individuales sufren caídas de entre 14 y 50 puntos mientras que la prueba con el corpus completo cae 33 puntos.

A partir de los resultados obtenidos en esta sección puede concluirse que la adición de forma conjunta de información semántica sobre los argumentos verbales proveniente de dichas ontologías puede resultar tan favorable en determinados casos como contraproducente en otros. Es por ello que a continuación se tratará de analizar el potencial de las ontologías descritas previamente mediante experimentos individualizados. Las variaciones en el rendimiento quedarán reflejadas en la comparación con los resultados de tareas anteriores en las que no se utilizaba información proveniente de ontologías.

En primer lugar, se pondrá a prueba el rendimiento de la información proporcionada por las diferentes ontologías en una clasificación basada en información sobre papeles temáticos, morfología y sintaxis de los argumentos verbales.

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Superar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
MS+PTs	96.90	95.12	76.69	97.67	76.92	98.76	89.36	95.60	97.56	73.62	88.57	60	87.70
MS+PTs+SUMO	96.90	95.12	81.55	96.51	84.61	97.53	88.29	92.30	97.56	75.82	87.14	70.76	88.77
MS+PTs+Ss	96.90	95.12	83.49	94.18	82.41	98.76	87.23	94.50	97.56	78.02	87.14	72.30	89.44
MS+PTs+TCO	96.90	96.34	79.61	97.67	83.51	98.76	91.48	92.30	97.56	76.92	87.14	73.84	89.44

Tabla 5 – Resultados de la clasificación basada en información morfológico-sintáctica y papeles temáticos (MS+PTs) y las clasificaciones en las que se combina con las ontologías SUMO, Supersenses (Ss) y TCO.

Como puede observarse en la tabla 5, el uso individualizado de las diferentes ontologías produce resultados diversos: del mismo modo que en la prueba que combinaba las tres ontologías, en esta ocasión la mayoría de los verbos se benefician de la adición de información semántica extra; llegando a una mejora de entre 1 y 2 puntos con el corpus completo. Si se comparan los resultados obtenidos con la ayuda de cada una de las ontologías, parece que se obtiene una mayor mejora en los resultados obtenidos a partir

de TCO; que se halla seguida de cerca por los Supersenses y, con mayor diferencia, por SUMO.

En una nueva clasificación pueden observarse las diferencias en el rendimiento de cada una de las ontologías junto a la información morfológica y sintáctica esta vez sin papeles temáticos (tabla 6).

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Superar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
MS	97.93	63.41	66.01	89.53	75.82	39.50	59.57	59.34	97.56	59.34	72.85	52.30	70.18
MS+SUMO	96.90	58.53	70.87	89.53	85.71	37.03	62.76	58.24	97.56	61.53	72.85	56.92	70.76
MS+Ss	97.93	54.87	74.75	86.04	82.41	29.62	65.95	63.73	97.56	62.63	77.14	50.76	71.05
MS+TCO	97.93	59.75	72.81	88.37	84.61	38.27	71.27	62.63	97.56	62.63	78.57	53.84	72.02

Tabla 6 – Resultados de la clasificación basada en información morfológica y sintáctica (MS) y las clasificaciones en las que esta se combina con las ontologías SUMO, Supersenses (Ss) y TCO.

A partir de los resultados mostrados en la tabla 6 y comparando con los previamente obtenidos en la prueba anterior, queda patente de nuevo que la eliminación de los papeles temáticos supone una merma en el rendimiento independientemente de la ontología empleada y de la presencia de información morfológica o sintáctica. Dicha merma se traduce en un descenso de los resultados que puede moverse desde un modesto 1 hasta los 60 puntos en las pruebas individuales en función del verbo y ontología escogidos y que se sitúa en unos 18 puntos al emplear el corpus completo. En esta ocasión, además, resulta incluso más difícil establecer con claridad qué ontologías dan lugar a un mayor rendimiento; si bien los resultados proporcionados por la tarea con el corpus completo parecen indicar que SUMO vuelve a quedar por detrás de los Supersenses y TCO.

Siguiendo el patrón establecido por el experimento en el que se pretendía medir el rendimiento conjunto de las tres ontologías, puede resultar interesante comprobar de nuevo cómo se comportan dichas ontologías, esta de vez de forma individual, cuando solo se hallan acompañadas de información relativa a los papeles temáticos. Los resultados obtenidos en esta prueba y expresados en la próxima tabla (tabla 7) reflejan, una vez comparados con los resultados de las anteriores, el hecho de que a nivel general la ausencia de información morfológica y sintáctica ofrece mayores beneficios que pérdidas: son pocos los verbos que muestran una leve pérdida de precisión en esta situación mientras que, por otro lado, son mayoría aquellos que experimentan leves

mejoras en sus resultados; esta situación de mejora queda patente en el incremento de precisión de 1 punto que ha tenido lugar al emplear el corpus completo. Como sucedía en los casos anteriores, de nuevo resulta difícil establecer cuál de las ontologías es de mayor utilidad en la tarea de desambiguación; aunque los resultados del corpus completo parecen volver a situar a TCO ligeramente por delante de los Supersenses y a ambas con una clara ventaja frente a SUMO.

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Superar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
PTs	96.90	95.12	80.58	96.51	79.12	98.76	89.36	95.60	97.56	80.21	84.28	67.69	89.25
PTS+SUMO	96.90	93.90	83.49	96.51	83.51	97.53	88.29	92.30	97.56	80.21	84.28	75.38	89.35
PTs+Ss	96.90	95.12	83.49	94.18	87.91	97.53	85.10	95.60	97.56	79.12	82.85	81.53	90.12
PTs+TCO	96.90	93.90	83.49	96.51	84.61	97.53	91.48	93.40	97.56	78.02	82.85	76.92	90.31

Tabla 7 – Resultados de la clasificación basada en información sobre papeles temáticos (PTs) y las clasificaciones en las que se combina con las ontologías SUMO, Supersenses (Ss) y TCO.

Finalmente, en el último de esta serie de experimentos se pondrá a prueba hasta qué punto la información recogida en cada una de las diferentes ontologías podría ser capaz de sustentar una aplicación de DVA por sí misma (tabla 8).

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Superar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
<i>Baseline</i>	61.85	64.63	65.04	52.32	48.35	41.97	36.17	41.75	76.82	40.65	60	32.30	52.17
SUMO	67.01	59.75	72.81	52.32	67.03	45.67	42.55	46.15	76.82	38.46	58.57	46.15	55.85
Ss	53.60	63.41	62.13	52.32	71.42	33.33	38.29	52.74	79.26	40.65	58.57	47.69	55.75
TCO	61.85	58.53	70.87	59.30	73.62	40.74	39.36	52.74	70.73	42.85	61.42	46.15	57.11

Tabla 8 – Resultados de la clasificación basada únicamente en las ontologías SUMO, Supersenses (Ss) y TCO.

Del mismo modo que en la prueba que analizaba el rendimiento conjunto de las tres ontologías (tabla 4), cuando se lleva a cabo una clasificación en la que las diferentes ontologías no cuentan con ningún tipo de información adicional, se produce una merma en los resultados que en el mejor de los casos alcanzan los 73 puntos pero en el peor de ellos se quedan con tan solo 33; resultados en ocasiones muy cercanos a la *baseline* y que son, por lo tanto, demasiado bajos como para ser aceptables. Cabe destacar, por otro lado, que para cada uno de los verbos se puede hallar una ontología que ofrece un resultado claramente mejor que el obtenido por las otras dos. Como ya se apuntaba anteriormente, los resultados obtenidos al emplear el corpus completo permiten

apreciar, de nuevo, que el empleo de la información proporcionada por TCO supera en hasta 2 puntos a las tareas basadas en Supersenses o SUMO.

Finalmente, en el gráfico 2 puede contrastarse el rendimiento de las diferentes ontologías en una clasificación basada en información sobre papeles temáticos; configuración que ha resultado ser la que ha proporcionado unos mejores resultados hasta la fecha.

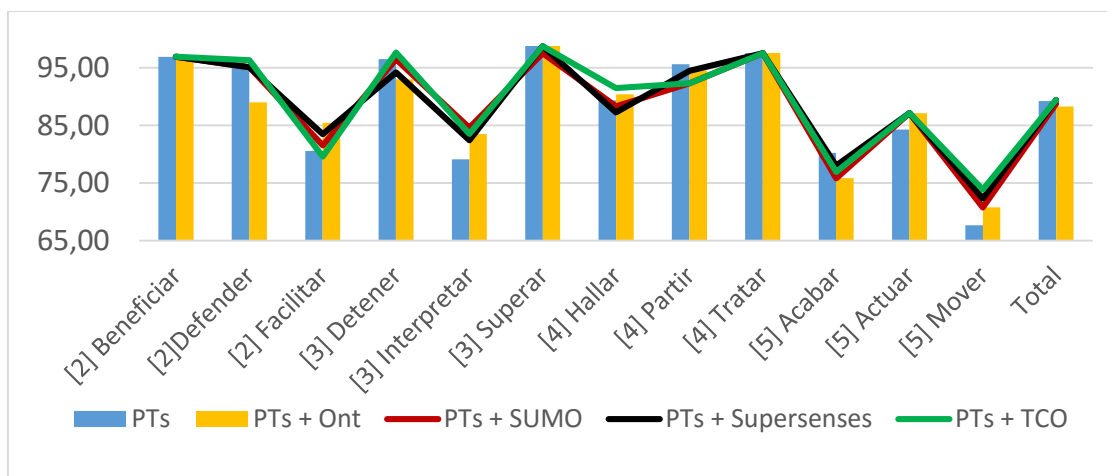


Gráfico 2 – Resultados obtenidos en una clasificación basada en papeles temáticos (PTs); papeles temáticos y las tres ontologías (PTs+Ont); y papeles temáticos con cada una de las tres ontologías de forma individual: SUMO, Supersenses (Ss) y TCO.

3.4.4. Aumentando el rendimiento de TCO

Los resultados descritos en las secciones anteriores hacen patente que en todas aquellas ocasiones en las que se ha evaluado el comportamiento de las tres ontologías contempladas en este estudio, TCO ha igualado o incluso mejorado el resultado de los Supersenses y, especialmente, de SUMO. Por otro lado, como se apuntaba anteriormente en la descripción de la metodología de esta investigación, el hecho de que el formato requerido por Weka admita un único valor para cada atributo limita en gran medida la utilidad de TCO si se tiene en cuenta su naturaleza jerárquica y componencial. Como puede verse en las instancias que se ofrecen a continuación a modo de ejemplo (figura 3), la limitación de un valor por atributo lleva al clasificador a entender como valores diametralmente distintos todos aquellos que se diferencien por una sola característica aun compartiendo parte o la totalidad de las demás.

Agentive_Cause_Dynamic_Purpose
Agentive_Cause_Dynamic_Purpose_Social

Figura 3 – Ejemplos de etiquetado TCO de dos instancias pertenecientes a un mismo sentido del verbo “beneficiar”.

Esta situación lleva a preguntarse si sería posible generalizar de algún modo la información sobre los argumentos verbales recogida en esta ontología, de forma que se pudieran relacionar los diferentes argumentos encontrados para cada sentido de un determinado verbo y, de este modo, caracterizar las preferencias de selección de cada uno de los sentidos posibles de este. Sería de esperar que la inclusión de esta información fuera útil para la DVA; cosa que se traduciría en una mejora de los resultados. A partir de esta premisa, y con la finalidad de aumentar la utilidad de TCO en este tipo de tareas, se propone a continuación una iniciativa basada en la descomposición de la información aportada por TCO en sus primitivas semánticas individuales y un posterior proceso de *clustering* en tantos grupos como sentidos posee un determinado verbo. Para poner a prueba esta nueva información se llevará a cabo una última prueba con la configuración que hasta la fecha ha resultado más favorable a TCO y se comprobará si la adición de la información producto del proceso de *clustering* antes descrito ofrece alguna mejora. Para generar las clases fruto del proceso de *clustering* utilizadas en esta prueba se ha empleado el algoritmo Simple-K-Means implementado en Weka.

	[2] Beneficiar	[2] Defender	[2] Facilitar	[3] Detener	[3] Interpretar	[3] Separar	[4] Hallar	[4] Partir	[4] Tratar	[5] Acabar	[5] Actuar	[5] Mover	Total
PTs+TCO	96.90	93.90	83.49	96.51	84.61	97.53	91.48	93.40	97.56	78.02	82.85	76.92	90.31
PTs+TCO+Clust	96.90	95.12	88.34	97.67	87.91	97.53	91.48	93.40	97.56	78.02	80	81.53	90.12

Tabla 9 – Resultados obtenidos en una clasificación basada en información sobre papeles temáticos y TCO (PTs+TCO) y una clasificación basada en papeles temáticos, TCO e información producto del *clustering* (PTs+TCO+Clust).

A la luz de los resultados representados en la tabla 9, se puede observar que la adición de esta nueva información en forma de *clusters* mantiene los resultados obtenidos en las pruebas de evaluación de TCO anteriores y en diversas ocasiones ofrece mejoras de entre 1 y 5 puntos. No obstante, hay que destacar que en otras ocasiones puede causar una ligera merma como se observa en el verbo “actuar” (2 puntos) y el corpus completo (0,2 puntos). Pese a estas ligeras mermas, parece ser que la inclusión de información producto de *clustering* permite salvar, al menos en parte, las limitaciones impuestas por el formato establecido por el clasificador y ayudar a mejorar los resultados obtenidos hasta el momento.

El tercer y último gráfico (gráfico 3) refleja las variaciones en el rendimiento causadas por la adición de las clases generadas por *clustering*.




Gráfico 3 – Resultados de la clasificación basada en información sobre papeles temáticos y TCO (PTs+TCO) y la clasificación basada en papeles temáticos, TCO e información producto del clustering (PTs+TCO+Cluster).

3.5. Discusión de los resultados

Los experimentos que se han llevado a cabo en la sección anterior y los resultados que estos aportan permiten realizar una serie de consideraciones sobre la utilidad de las diferentes informaciones empleadas. En primer lugar, se ha podido comprobar que el uso exclusivo de información morfológica y sintáctica acerca de los argumentos verbales mejora los resultados proporcionados por la *baseline* pero resulta insuficiente para llevar a cabo una tarea de desambiguación con resultados aceptables. En segundo lugar, se ha comprobado con claridad que la adición de información relativa a los papeles temáticos desempeñados por cada argumento incrementa de forma notable el rendimiento de estas tareas. Es más, de hecho se ha podido observar que la información sobre papeles temáticos puede ofrecer mejores resultados si prescinde de información morfológica y sintáctica; probablemente debido a que dichos papeles temáticos ya incluyen de algún modo una representación de las características morfológicas y sintácticas de cada argumento verbal. En tercer lugar, se ha podido comprobar también cómo el uso de la información proporcionada por ciertas ontologías puede mejorar la desambiguación de determinados verbos. En todo caso, los mejores resultados se han obtenido con el apoyo de los papeles temáticos, prescindiendo de la información morfológica y sintáctica, y empleando únicamente una de las tres ontologías señaladas. En cuanto a las diferencias de rendimiento entre estas, se ha podido observar que SUMO se ve claramente superada por los Supersenses y TCO así como que esta última se destaca como la más fructífera de las tres. Esto probablemente se deba al hecho de

que, como se ha comentado anteriormente, las 2.302 categorías que conforman SUMO la hacen una ontología demasiado específica que impediría establecer de forma adecuada generalizaciones a partir de diferentes argumentos relacionados con un mismo sentido verbal. Por otro lado, esto no parece suceder con ontologías como los Supersenses o TCO que con un menor número de categorías (25 y 64, respectivamente) reflejan un mayor grado de abstracción y, por lo tanto, sí permitirían relacionar argumentos diversos. En relación con esta última ontología, cabe destacar que los resultados obtenidos a partir de la adición de información basada en el *clustering* de sus categorías son el indicador de una posible vía para aumentar su contribución en tareas de desambiguación.

A partir de lo anteriormente expuesto, puede concluirse que las hipótesis de partida de esta investigación han sido verificadas: en primer lugar, es posible mejorar la eficiencia de la DVA si se tiene en cuenta información referente a los argumentos verbales. En segundo lugar, la información semántica ha demostrado ser especialmente útil para esta finalidad.

En último lugar, y a modo de apunte, si se comparan los resultados obtenidos en las diferentes pruebas realizadas de forma individual para cada verbo, se puede considerar que no existe una clara relación entre el número de sentidos establecido y un mayor o menor rendimiento en la desambiguación de estos. Por ejemplo, verbos con cuatro sentidos como “tratar” y “partir” han alcanzado mejores resultados a lo largo del estudio que otros verbos con un menor número de sentidos como son “facilitar” e “interpretar”, con dos y tres sentidos respectivamente. Así pues, a la luz de esta observación y teniendo en cuenta la noción de preferencias de selección, parece más probable que la capacidad de desambiguación verbal se deba a un aspecto cualitativo, de modo que cada sentido tenga unas preferencias propias en cuanto a características morfológicas, sintácticas y semánticas de sus posibles argumentos verbales, y no a una cuestión meramente cuantitativa; es decir, dependiente del número de sentidos asociados a dicho verbo.

4. Conclusión

A lo largo de este trabajo se ha realizado una descripción del concepto de Desambiguación Semántica Automática (DSA), sus principales características, aproximaciones y aplicaciones. En concreto, se ha centrado el foco de atención en la cuestión de la Desambiguación Verbal Automática (DVA): su estado de desarrollo actual y posibles vías de estudio futuro. Así mismo, se ha propuesto una aproximación a la DVA basada en la información semántica de los argumentos verbales representada en forma de los papeles temáticos que interpretan y la clasificación de dichos argumentos según diversas ontologías. Los buenos resultados obtenidos en este estudio (90% para el corpus completo empleando papeles temáticos y TCO) sentarían un nuevo precedente a la hora de tener en cuenta estas informaciones en futuros sistemas de DVA. De cara a validar estos resultados, sería interesante realizar de nuevo los diferentes experimentos llevados a cabo en este estudio con un corpus de mayor tamaño; no solo en número de verbos sino también en número de sentidos y ejemplos por verbo. Así mismo, podría resultar interesante aplicar esta aproximación a uno de los diferentes corpus que participan en competiciones oficiales de PLN para, de este modo, contrastar su rendimiento con el de otras aproximaciones vigentes.

Referencias bibliográficas

- Abend, O., Reichart, R. y Rappoport, A. (2008). "A supervised algorithm for verb disambiguation into VerbNet classes". En *Proceedings of the 22nd International Conference on Computational Linguistics*, vol. 1, p. 9-16, Association for Computational Linguistics (ACL), Stroudsburg, USA
- Alexopoulou, D., Andreopoulos, B., Dietze, H., Doms, A., Gandon, F., Hakenberg, J., ... y Wächter, T. (2009). *Biomedical Word Sense Disambiguation with Ontologies and Metadata: Automation Meets Accuracy*. BMC Bioinformatics, vol. 10. Recuperado de: <http://bmcbioinformatics.biomedcentral.com/articles/10.1186/1471-2105-10-28>
- Alonso, L., Capilla, J.A., Castellón, I., Fernández, A. y Vázquez, G. (2007). "The Sensem project: Syntactico-semantic annotation of sentences in Spanish". En Nikolov, K. et al. (Ed.) *Recent Advances in Natural Language Processing IV. Selected papers from RANLP 2005*, p. 89-98, John Benjamins Publishing Co, Philadelphia, USA
- Álvez, J., Atserias, J., Carrera, J., Climent, S., Oliver, A. y Rigau, G. (2008). "Consistent annotation of EuroWordNet with the Top Concept Ontology". En Tanács et al., (Ed.) *Proceedings of the 4th Global WordNet Conference*, University of Szeged, Szeged, Hungría
- Buscaldi, D., Rosso, P., Pla, F., Segarra, E. y Arnal, E.S. (2006). "Verb sense disambiguation using support vector machines: Impact of WordNet-extracted features". En Gelbuk et al., (Ed.) *Computational Linguistics and Intelligent Text Processing (CICLing 2006)*, p. 192-195, Springer, New York, USA
- Castellón, I., Climent, S., Coll-Florit, M., Lloberes, M. y Rigau, G. (2012). "Constitución de un corpus de semántica verbal del español: Metodología de anotación de núcleos argumentales." En *RLA. Revista de Lingüística Teórica y Aplicada*, num. 50, p. 13-38, Universidad de Concepción, Concepción, Chile.
- Cuadros, M. (2011). *Multilingual Acquisition of Large Scale Knowledge Resources* (tesis), Universitat Politècnica de Catalunya, Barcelona, España
- Dang, H.T. y Palmer, M. (2005). "The role of semantic roles in disambiguating verb senses". En *Proceedings of the 43rd Annual Meeting on Association for Computational Linguistics*, p. 42-49, Association for Computational Linguistics (ACL), Stroudsburg, USA
- Del Corro, L., Gemulla, R. y Weikum G. (2014). "Werdy: Recognition and disambiguation of verbs and verb phrases with syntactic and semantic pruning". En *Conference on Empirical Methods in Natural Language Processing*, p. 374-385, Association for Computational Linguistics (ACL), Stroudsburg, USA

- Dligach, D. y Palmer, M. (2008). "Novel semantic features for verb sense disambiguation". En *Proceedings of the 46th Annual Meeting of the Association for Computational Linguistics on Human Language Technologies: Short Papers*, p. 29-32, Association for Computational Linguistics (ACL), Stroudsburg, USA
- Escudero, G. (2006). *Machine Learning Techniques for Word Sense Disambiguation* (tesis), Universitat Politècnica de Catalunya, Barcelona, España
- Fellbaum, C. (2005). "WordNet and Wordnets". En Brown et al. (Ed.), *Encyclopedia of Language and Linguistics*, 2ª edición, p. 665-670, Elsevier, Oxford, U.K
- Fernández-Montraveta, A. y Vázquez, G. (2014). "The SenSem Corpus: An annotated corpus for Spanish and Catalan with information about aspectuality, modality, polarity and factuality" En Wuff, S. (Ed.) *Corpus Linguistics and Linguistic Theory*, vol. 10, p. 273-288, De Gruyter, Berlin, Alemania
- Halliday, M.A. y Hasan, R. (Ed.) (1976). *Cohesion in English*. Longman Group Ltd, London, U.K
- Kasture, N.R. y Agrawal, A. (2012). "A supervised word sense disambiguation method using ontology and context knowledge". En *Computer Engineering and Intelligent Systems*, vol. 3, num. 8, iiste, New York, USA
- Kohomban, U. y Sun Lee, W. (2005). "Learning semantic classes for word sense disambiguation". En *Proceedings of the 43rd Annual Meeting on Association for Computational Linguistics*, p. 31-41, Association for Computational Linguistics (ACL), Stroudsburg, USA
- Lesk, M. (1986). "Automatic sense disambiguation using machine readable dictionaries: How to tell a pine cone from an ice cream cone". En Debuys et al. (Ed.), *SIGDOC 86 Proceedings of the 5th annual international conference on Systems documentation*, p. 24-26, ACM, New York, USA
- Lin, S. y Verspoor, K. (2008). "A semantics-enhanced language model for unsupervised word sense disambiguation". En *9th International Conference on Computational Linguistics and Intelligent Text Processing (CICLing 2008)*, p. 287-298, Springer, New York, USA
- Mallery, J.C. (1988). *Thinking About Foreign Policy: Finding an Appropriate Role for Artificially Intelligent Computers* (tesis), MIT Political Science Department, St. Louis, USA
- Mihalcea, R. (2002). "Bootstrapping large sense tagged corpora". En *Proceedings of the 3rd International Conference on Languages Resources and Evaluations (LREC 2002)*, p. 1407-1411, ELRA-ELDA, Las Palmas, España

- Mihalcea, R. y Moldovan, D. (1998). "Word sense disambiguation based on semantic density". En *Proceedings of COLING-ACL '98 Workshop on Usage of WordNet in Natural Language Processing Systems*, p16-22, Montreal, Canada
- Navigli, R. (2009). "Word sense disambiguation: A survey". En *ACM Computing Surveys (CSUR)*, vol. 41, ACM, New York, USA
- Patwardhan, S., Banerjee, S. y Pedersen, T. (2003). "Using measures of semantic relatedness for word sense disambiguation". En *Proceedings of the Fourth International Conference on Intelligent Text Processing and Computational Linguistics*, p. 241-257, Springer, New York, USA
- Pease, A., Niles, I. y Li, J. (2002). "The Suggested Upper Merged Ontology: A large ontology for the semantic web and its applications". En *Working Notes of the AAAI-2002 Workshop on Ontologies and the Semantic Web*, vol. 28, p. 7-10, Association for the Advancement of Artificial Intelligence (AAAI), California, USA
- Platt, J. (1998). "Fast training of support vector machines using Sequential Minimal Optimization". En Schölkopf et al. (Ed.) *Advances in Kernel Methods - Support Vector Learning*, The MIT Press, Cambridge, U.K
- Pal, A. y Saha, D. (2015). "Word sense disambiguation: A survey". En *International Journal of Control Theory and Computer Modeling (IJCTCM)*, vol. 5, num. 3, AIRCC, Chennai, India
- Savova, G., Pedersen, T., Purandare, A. y Kulkarni, A. (2005). "Resolving ambiguities in biomedical text with unsupervised clustering approaches". En *University of Minnesota Supercomputing Institute Research Report*, University of Minnesota, Minneapolis, USA
- Tsatsaronis, G., Varlamis, I. y Vazirgiannis, M. (2008). "Word sense disambiguation with semantic networks". En *11th International Conference on Text, Speech and Dialogue*, p. 219-226, Brno, Rep. Checa.
- Wagner, W., Schmid, H. y Im Walde, S.S. (2009). "Verb sense disambiguation using a predicate-argument-clustering model". En *Proceedings of the CogSci Workshop on Distributional Semantics beyond Concrete Concepts (DiSCo)*, p. 23-28, Amsterdam, Países Bajos
- Wang, X., Zuo, W. y Wang, Y. (2013). "A novel approach to word sense disambiguation based on topical and semantic association". En *The Scientific World Journal*, Hindawi Publishing Co. Recuperado de: <http://www.hindawi.com/journals/tswj/2013/586327/>

Witten, I., Frank, E. y Hall, M.A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques*. Elsevier, Burlington, USA

Ye, P. y Baldwin, T. (2006). “Verb sense disambiguation using selectional preferences extracted with a state-of-the-art semantic role labeler”. En *Proceedings of the Australasian Language Technology Workshop*, p.139-148, Australasian Language Technology Association (ALTA), Sidney, Australia

Zhong, Z. y Tou Ng, H. (2010). “It Makes Sense: A wide-coverage word sense disambiguation system for free text”. En *48th Annual Meeting of the Association for Computational Linguistics*, p. 78-83, Association for Computational Linguistics (ACL), Stroudsburg, USA

Anexo 1. Descripción del corpus

En la siguiente tabla se presentan los diferentes verbos que forman parte del corpus en que se basa esta investigación. Para cada verbo se proporcionan los diferentes sentidos recogidos y el número de oraciones de ejemplo (instancias) que contiene cada uno de ellos así como su proporción dentro del total.

Verbo	Sentido Sensem	Instancias
Beneficiar	1-Ser de ayuda para alguien o algo	37 (38%)
	2-Mejorar lo personal aprovechándose en el buen sentido de algo	60 (62%)
Defender	1-Dar amparo físico, moral, ideológico o legal a alguien o algo	29 (35%)
	3-Apoyar una idea o causa	53 (65%)
Facilitar	1-Poner los medios necesarios para que algo resulte más fácil de conseguir	67 (65%)
	2-Dar algo a alguien que lo necesita; entregar	36 (35%)
Detener	1-Obstaculizar el movimiento de algo	14 (17%)
	2-Capturar a alguien que ha cometido un delito	46 (54%)
	3- Interrumpir el propio movimiento	24 (29%)
Interpretar	1-Entender el sentido o significado de una cosa o comprender la realidad de un modo personal	44 (49%)
	2-Characterizar a un personaje en una actuación	25 (27%)
	3-Tocar o bailar una pieza musical	22 (24%)
Superar	1- Vencer a alguien o algo en una prueba	34 (42%)
	2-Traspasar un límite físico o mental	26 (32%)
	3-Tener algo un tamaño superior al resto	21 (26%)
Hallar	1-Llegar a ver algo o a alguien que se buscaba	34 (36%)
	2-Solucionar algo que estaba oculto o desconocido; localizarlo	9 (10%)
	3-Encontrarse alguien o algo en algún lugar	29 (31%)
	5-Encontrarse alguien o algo en un estado determinado	22 (23%)

Verbo	Sentido Sensem	Instancias
Partir	1- Hacer dos partes o más de lo que estaba entero; fragmentar algo	10 (11%)
	2-Abandonar un lugar; marchar hacia otro destino	34 (37%)
	3-Surgir una idea o cosa de alguien o algo	38 (42%)
	5-Participar alguien en un proceso de una determinada manera	9 (10%)
Tratar	1-Atender o dirigirse a alguien de un modo determinado	7 (8%)
	8-Hablar sobre un tema	7 (8%)
	9-Intentar que algo ocurra	7 (8%)
	10-Ser algo el tema o tópico	63 (76%)
Acabar	1-Dar final alguien o algo a algún evento	37 (40%)
	3-Destruir; aniquilar; erradicar algo o alguien	15 (16%)
	4-Ser una cosa en su final de una forma determinada	5 (6%)
	7-Quedar algo o alguien en una situación, lugar o forma determinadas	18 (20%)
	8-Finalizarse algo	16 (17%)
Actuar	2-Funcionar de una forma determinada	7 (10%)
	3-Realizar actos de forma determinada	42 (61%)
	4- Desempeñar las funciones que le son características a una determinada posición	5 (7%)
	5-Formar parte visible de un espectáculo audiovisual frente un público	8 (11%)
	6-Provocar una cosa efecto sobre alguien o algo	8 (11%)
Mover	1-Emplazar un cuerpo en un lugar distinto del que ocupa	21 (32%)
	2-Hacer algo o alguien que un objeto o parte de éste se agite	20 (31%)
	3-Provocar algo que alguien actúe o sienta de una determinada manera	9 (14%)
	6-Saber desenvolverse en un determinado ámbito o una situación	6 (9%)
	7-Desplazarse algo o alguien	9 (14%)