

## ETIQUETADO GRAMATICAL Y LEMATIZACIÓN EN EL *CORPUS HISTÓRICO JUDEOESPAÑOL (CORHIJE)*: PROBLEMAS, SOLUCIONES Y RESOLUCIONES\*

AITOR GARCÍA MORENO (*ILC-CSIC / IUMP*)

aitor.garcia@cchs.csic.es

F. JAVIER PUEYO MENA (*College of the Holy Cross*)

javier.pueyo@gmail.com

### RESUMEN

Tras un breve repaso de las características más sobresalientes del [Corpus Histórico Judeoespañol - CORHIJE](#) —a modo de recordatorio, pues ya fue presentado en la III edición del *Congreso de Corpus Diacrónicos en lenguas Iberorrománicas (CODILI)* en 2014 en Zurich—, mostraremos el proceso de lematización y etiquetado gramatical que se está llevando a cabo sobre el mismo, pasando revista a los distintos problemas detectados y a las soluciones aplicadas durante el mismo que, en algunos casos, nos han obligado a tomar resoluciones, relativamente arbitrarias, en función de los objetivos de descripción y análisis perseguidos: *problemas, soluciones y resoluciones* que amplifican el título de nuestra presentación.

**PALABRAS CLAVE:** Corpus lingüísticos, diseño de corpus electrónicos, judeoespañol, diacronía.

## LEMATIZATION AND GRAMMATICAL ANNOTATION OF THE *CORPUS HISTÓRICO JUDEOESPAÑOL (CORHIJE)*: PROBLEMS, SOLUTIONS, AND RESOLUTIONS

### ABSTRACT

After a brief review of the most salient features of the [Corpus Histórico Judeoespañol - CORHIJE](#) —which was already presented at the 3<sup>rd</sup> Edition of the *Congreso de Corpus Diacrónicos en lenguas Iberorrománicas (CODILI)*, Zurich 2014—, this paper describes the ongoing process of lemmatization and grammatical annotation of the corpus. We focus on describing the challenges we have encountered during the annotation process and the solutions we have applied to them, which, in some cases, have led us to take relatively arbitrary resolutions in accordance with the description and analysis goals we were trying to achieve: *problems, solutions, and resolutions* that amplify the title of our presentation.

**KEY WORDS:** Linguistic Corpora, Digital Corpus Design, Judeo-Spanish, Diachrony.

Si cualquier corpus diacrónico presenta no pocos retos a la hora de anotar lingüísticamente los diferentes estadios y registros de la lengua a lo largo del tiempo, la variedad judeoespañola añade los suyos propios, debido a su falta de unificación en cada período histórico tanto en el apartado gráfico (textos aljamiados en grafía hebrea o cirílica y textos latinados con diferentes ortografías), como en el léxico o en el morfológico. A esto se añaden su alto grado de diversidad dialectal y la dispersión geográfica de sus hablantes; y es que el judeoespañol presenta en cada período sincrónico una destacable variación gráfica, fonética y morfológica, y se caracteriza —en el ámbito léxico— por la incorporación de préstamos de lenguas diversas, como el hebreo, el turco, el francés, el neogriego o las lenguas eslavas, entre otras.

---

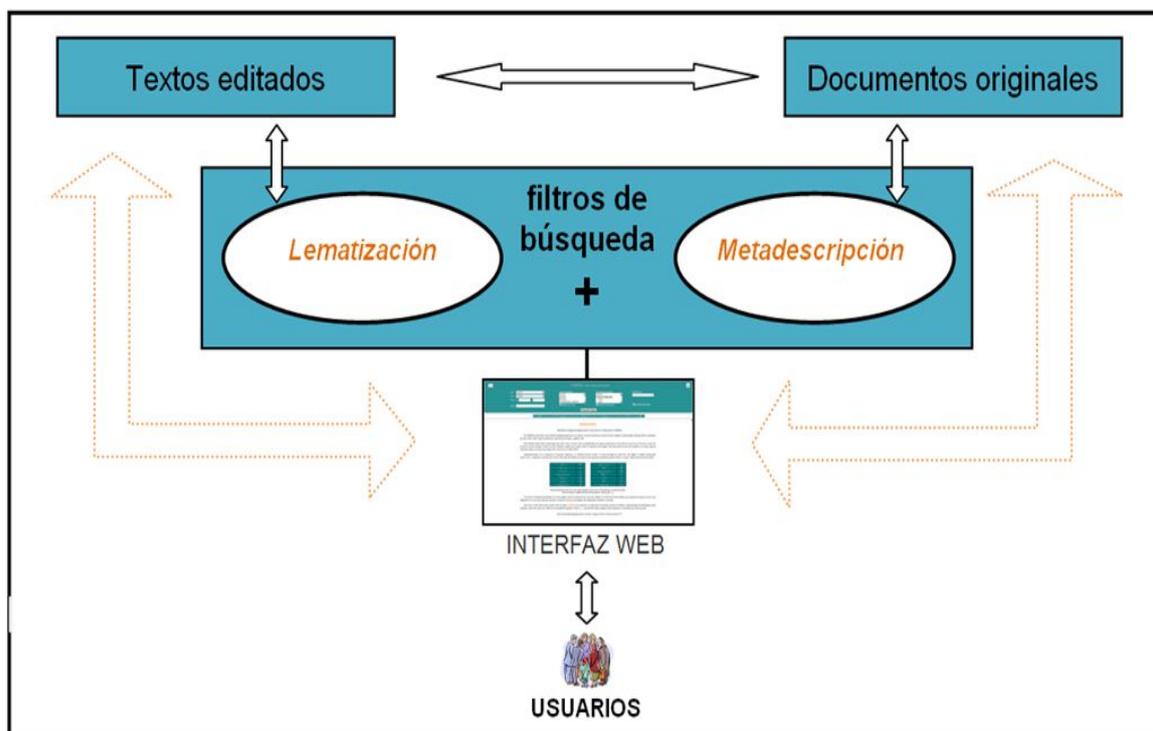
\* Este trabajo se enmarca dentro del proyecto de investigación «Sefarad, siglo XXI (2017-2020): edición y estudio filológico de textos sefardíes» (ref. núm. FFI2016-74864-P), financiado por el Ministerio de Economía, Industria y Competitividad (MINECO).

## 1. EL CORHIJE 1.0

Tal y como se recoge en la página web de nuestro proyecto (García Moreno y Pueyo Mena 2012-2017), el [Corpus Histórico Judeoespañol \(CORHIJE\)](#)<sup>1</sup> es un corpus lingüístico accesible en línea, representativo de la evolución de la lengua sefardí, y que está concebido tanto para el investigador como para el lector curioso en general, por su carácter adicional de colección documental. Desde su interfaz web se pueden efectuar búsquedas lingüísticas complejas sobre un número creciente de ediciones críticas de textos sefardíes de todos los lugares, géneros y épocas, así como acceder a la reproducción fotográfica de los documentos originales.

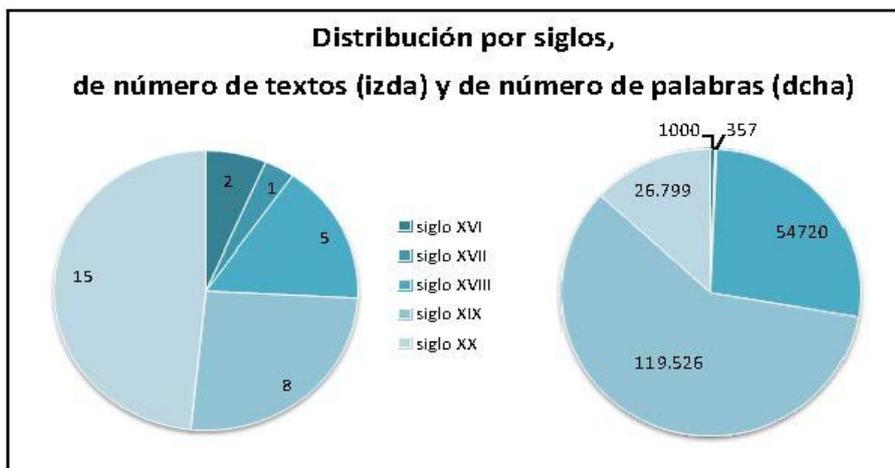
El primer prototipo, obra de F. Javier Pueyo Mena, se desarrolló entre enero de 2012 y diciembre de 2013 en el marco del proyecto *Towards a Representative Corpus of the History of Judeo-Spanish (the CORHIJE)* que englobaba a diversos equipos de investigación nacionales y extranjeros, y que fue financiado por la Vicepresidencia de Relaciones Internacionales del CSIC por medio de la ayuda I-LINK-0324.

Como podemos apreciar en el siguiente diagrama, la estructura general del *CORHIJE* combina elementos propios de las colecciones documentales digitales (zona derecha) con otros habituales de los corpus lingüísticos (zona izquierda):

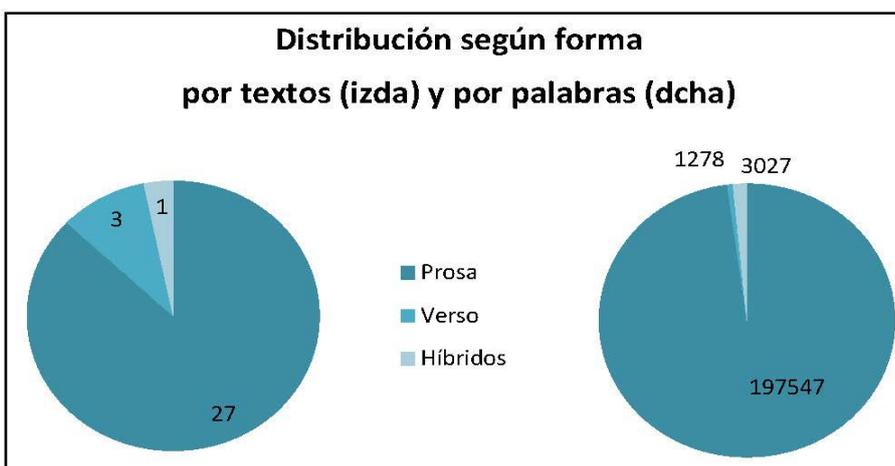


En cifras, el *CORHIJE* contiene actualmente **31 textos** (con un total de **201.852 palabras**) que van desde unas pocas líneas (con 82 palabras el más corto) a las 200 páginas (con 38.430 palabras el más largo) distribuidos por siglos como sigue:

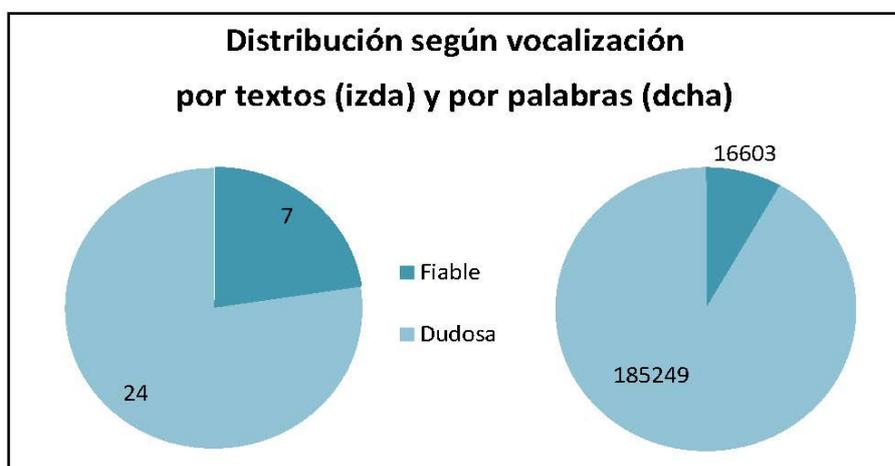
<sup>1</sup> Fecha de última consulta: 15 de enero de 2017.



De estos, **27** son textos en prosa (con 197.547 palabras en total), **3** son textos en verso (1.278 palabras) y **1** (de 3.027 palabras) tiene carácter híbrido por corresponder a un libro de refranes.

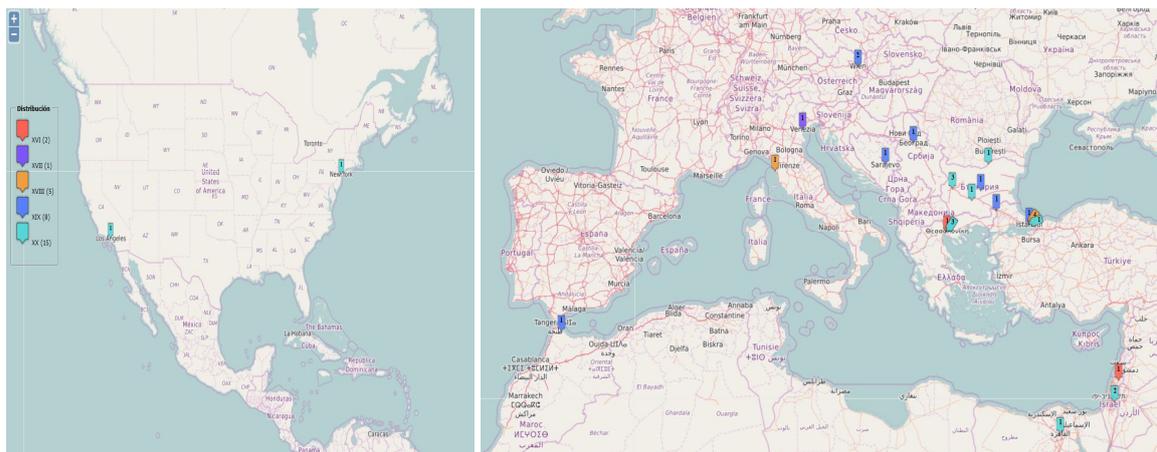


Asimismo, cabe destacar que **7** de ellos ofrecen una vocalización fiable por corresponder a la transcripción de textos orales, textos aljamiados vocalizados, textos escritos en caracteres cirílicos o textos en escritura latina.



Por último, desde el punto de vista geográfico —para el que se tienen en cuenta tanto el lugar de publicación o producción del texto como el lugar de origen de su responsable (autor, editor, manuscrita, etc.) cuando se conoce— las ciudades representadas actualmente en el corpus, por orden alfabético, son las siguientes: Adrianópolis/Edirne, Belgrado, Bucarest, Constantinopla/Estambul, El Cairo, Esmirna, Filipópolis/Plovdiv, Jerusalén, Kazanlâk, Liorna, Los Ángeles, Nueva York, Ruse/Rustchuk, Safed, Salónica, Sarajevo, Sofía, Tetuán, Venecia, Viena y Xanthi.

El siguiente mapa muestra dicha distribución por lugares, según el número de textos asociados a cada localización y a los siglos de composición:



## 2. HACIA EL CORHIJE 2.0

A partir de transcripciones normalizadas de los textos en aljamía hebrea o cirílica — mediante el uso de diacríticos sobre la grafía hispánica estándar que indican la realización propia del sefardí sobre la base del sistema ideado por Hassán (1978) y, en el caso de los textos latinados, respetando sus propios usos ortográficos pero adaptando la acentuación y puntuación a la ortografía hispánica—, el desarrollo de lo que podríamos denominar *CORHIJE 2.0* añade nuevas capas de marcación lingüística (lematización y etiquetado gramatical), mapas para la proyección de los resultados de las consultas y, por supuesto, un motor de búsqueda y de obtención de resultados que permite hacer uso de dichas capas de anotación y visualizarlas correctamente.

Para dar cuenta de las peculiaridades del judeoespañol en sus diversas variantes gráficas, y atender a sus variedades diacrónicas y geográficas, decidimos utilizar para el procesamiento lingüístico de los textos la herramienta *Freeling* (Padró 2011), un conjunto de recursos y programas informáticos para el Procesamiento del Lenguaje Natural, que ya se había adaptado con éxito para la anotación lingüística de textos diacrónicos del español transcritos de forma semi-paleográfica en el HSMS (Sánchez Marco, Boleda y Padró 2011).

*Freeling* está pensado para el análisis multilingüe, utilizando varios módulos encadenados (*tokenizer*, *splitter*, analizador morfológico, etiquetador, desambiguador, etc.) que se sirven de los siguientes elementos para su funcionamiento:

- (1) **vocabularios y otros recursos léxicos** (de términos comunes, de nombres propios, de abreviaturas, de locuciones, etc.).

(2) **reglas de dos tipos:**

- (a) de segmentación textual (que le indican a *Freeling* qué secuencias debe considerar como frases, palabras o caracteres alfanuméricos).
- (b) de análisis lingüístico (por ejemplo, para el reconocimiento de partículas enclíticas, de morfemas derivativos o de terminaciones verbales).

(3) **un modelo probabilístico** generado a partir del análisis estadístico de un corpus de entrenamiento, y que se utiliza en los procesos de desambiguación de homónimos y en la asignación de un análisis final para aquellas formas desconocidas que no hayan recibido ninguno a partir de los recursos y reglas descritos anteriormente.

Esta arquitectura permite el uso de diccionarios y de otros recursos semánticos adaptados a cada lengua objetivo, así como el desarrollo de aquellas reglas lingüísticas que reflejen las características particulares de dichas lenguas.

## 2.1. Etiquetado

El proceso de adaptación de *Freeling* al judeoespañol pasa por crear, modificar, aumentar o eliminar recursos y reglas en los ámbitos señalados. Afortunadamente, hacerlo desde una lengua cercana al judeoespañol como es el español moderno facilita mucho las cosas, ya que, por ejemplo, la variante de *Freeling* para el español está ya diseñada para tener en cuenta una conjugación verbal rica, la presencia de elementos enclíticos, procesos de morfología derivativa, y una sintaxis hispánica en buena parte coincidente con la del judeoespañol: interrogativas, posición de adjetivos, concordancia de género, etc.

A. En el ámbito de los recursos léxicos, ha sido necesaria la creación de un diccionario electrónico a partir de los lemas actualmente incluidos en el [Diccionario Histórico del Judeoespañol - DHJE](#) (García Moreno 2008-2017)<sup>2</sup> y su ampliación, mediante el desarrollo de un flexionador de formas nominales y de un conjugador verbal, a partir de los infinitivos recogidos en el *DHJE*. El resultado es un diccionario inicial de *formas / lemas / etiquetas* de alrededor de 300.000 entradas que, en el caso de las formas verbales se han obtenido mediante el uso de un conjugador verbal del español estándar, cuyo análisis final se ha adaptado, a través de reglas sistemáticas, a las terminaciones y cambios de raíz propios del judeoespañol, teniendo en cuenta todas las variantes con diacríticos, como en los siguientes ejemplos:

*cant-é > cant-í*  
*perd-iste > perd-ites*

Las etiquetas usadas para describir la información lingüística de cada palabra siguen el estándar [EAGLES](#) para lenguas europeas, si bien en determinados casos ha sido necesario modificarlas o crear otras nuevas para describir de forma más precisa algunas formas del judeoespañol. Por ejemplo, para la anotación del participio activo de presente se creó la etiqueta:

*cantán* CANTAR VMPPPOS0

---

<sup>2</sup> 18.585, según la última consulta, realizada el día 15 de enero de 2017.

o para los adverbios en diminutivo:

*demaśiyadico* DEMASIADO RGD

B. En lo relativo a las reglas específicas para los diferentes módulos de procesamiento de *Freeling*, a saber: (a) reglas de división de palabras o *tokenizer*; (b) reglas de división en frases o *splitter*; (c) reglas de afijación, y d) reglas para la detección de expresiones multi-palabra, destaca el hecho de que en nuestro caso debíamos enfrentarnos, por un lado, al uso de guiones medios y bajos, utilizados en la transcripción normalizada para marcar, respectivamente, formas de escritura unitaria en la ortografía del español estándar que en judeoespañol tienden a notarse separadamente como ליב'י מינטי / *leve-mente*, y formas complejas de escritura unitaria en judeoespañol que en español estándar se notan separadamente, como מולו דיירון / *mo\_lo dieron*; y, por otro, con no pocos casos de expresiones (principalmente) hebreas insertas en algunos de los textos, y que representan casos claros de *cambio de código*, y que por lo tanto debían ser ignoradas por *Freeling*.

C. En cuanto a las reglas lingüísticas que se han creado o modificado, podemos citar la incorporación de clíticos propios del judeoespañol (con y sin diacríticos) y su reconocimiento en posiciones sintácticas ajenas a las del español estándar. Por ejemplo, se desarrollaron reglas para dar cuenta de clíticos que no existen en español (*lis, si, sin, mos/mos'*) o para anotar casos no existentes en español moderno, como los clíticos propuestos a una forma verbal conjugada (*dijolis*)<sup>3</sup>:

1	2	3	4	5	6	7	8	9	10
Clitic to erase from word form	Affix to add to the resulting root	Expected category	Tag for suffixed	Check lemma adding accents	Enclitic suffix (special accent behaviour in Spanish)	Prevent Freeling from assigning more tags to the word	Lemma/Form/Root/Affix to assign	Consider the suffix always, not only for unknown words	How to retokenize the word if necessary
lis	*	^V	*	1	1	0	L	1	\$\$+les:\$\$+PP
si	*	^V	*	1	1	0	L	1	\$\$+se:\$\$+PP
sin	*	^V	*	1	1	0	L	1	\$\$+se:\$\$+PP
mos	*	^V	*	1	1	0	L	1	\$\$+nos:\$\$+PP
mos'	*	^V	*	1	1	0	L	1	\$\$+nos:\$\$+PP

Por último, se tuvieron en cuenta todas las posibles combinaciones y posiciones del sistema de clíticos sefardí, por lo que formas complejas como *púsomoslo* (esp. *nos lo puso*) o *dijéronselo* (esp. *se lo dijeron*) se analizan correctamente a partir de una sola

<sup>3</sup> De acuerdo con la [Columna 1] le decimos a *Freeling* que en las secuencias terminadas en *-lis*, extraiga la cadena que le antecede (*dijo-*). [Columna 2] El asterisco le indica a *Freeling* que no debe quitar ni añadir nada a la forma *dijo* para continuar con el análisis (esto puede ser necesario en otros casos). [Columna 3] Si el resultado es cualquier verbo (conjugado o no: ^V) entonces *lis* puede y debe analizarse como clítico. [Columna 4] No se aplica a los clíticos. [Columnas 5 y 6] Los 1 y 0 son indicadores para *Freeling* sobre si debe intentar encontrar *dijo* tanto con tildes como sin ellas (en este caso es importante ya que la cadena con tilde *dijo* no existe en el diccionario, pero sí existe la forma sin tilde). [Columna 7] No se aplica a los clíticos. [Columna 8] La L indica que se debe asignar el mismo lema al conjunto *dijolis* que a *dijo*, esto es, DECIR. [Columna 9] Esta regla debe aplicarse tanto a palabras conocidas como a desconocidas. [Columna 10] Qué análisis (además de *Verbo*) debemos asignar al conjunto. En este caso, el mismo que a *les* (es decir: *Pronombre Personal, tercera persona del plural*).

entrada léxica y de una regla lingüística única que los describe a todos. El análisis final de *púšomoslo* resultaría en la siguiente anotación:

Forma	Lemas	Etiquetas
<i>púšomoslo</i>	poner+nos+lo	VMIS3S0+PP1CP000+PP3CNA00

La ampliación de reglas lingüísticas ha sido necesaria también, por ejemplo, para algunos casos particulares de afijación (diminutivos, aumentativos, etc.) del español sefardí. Así, la versión del español estándar de *Freeling* no contempla, por ejemplo, derivados en *-ico* (también escrito *-iko*), muy productivos en judeoespañol, por lo que hubo que añadir una regla específica para su reconocimiento. *Freeling* tampoco contempla que a partir de un adverbio puedan derivarse diminutivos, algo relativamente frecuente en judeoespañol, por lo que una vez creada la regla para *-ico/-iko*, hubo que ampliarla para que pudiera funcionar también con dichos adverbios, como vemos en la siguiente tabla para el tratamiento de la forma *demašiyadico*<sup>4</sup>.

1	2	3	4	5	6	7	8	9	10
Affix to erase from word form	Affix to add to the resulting root	Expected category	Tag for suffixed	Check lemma adding accents	Enclitic suffix (special accent behaviour in Spanish)	Prevent Freeling from assigning more tags to the word	Lemma/Form/Root/Affix to assign	Consider the suffix always, not only for unknown words	How to retokenize the word if necessary
ico	o	^RG	RGD	0	0	0	L	0	-

## 2.2. Lematización

En lo que corresponde a la lematización de *CORHIJE*, de una parte, se decidió hacerla compatible con la de otros corpus diacrónicos hispánicos, por lo que el lema de cada forma se introduce en el diccionario principal sin diacríticos (aunque sí con tildes ortográficas) y se elige la forma que mejor puede reflejar la correspondiente al español actual, cuando esta existe.

Sin embargo, para no dejar sin reflejar los fenómenos de variación (principalmente fonéticos) de carácter sistemático en español sefardí —los cambios en el timbre vocálico (incluido el cierre de vocales medias en posición átona), los casos de aféresis, prótesis, metátesis, epéntesis y paragoge, las asimilaciones y disimilaciones, etc.— y permitir así proyectarlos sobre los mapas dialectales que se producen al realizar consultas sobre el corpus, se decidió crear un nivel superior de lematización que los recogiera, por lo que cada *forma* recibe un LEMA y una especie de ARCHILEMA.

Mientras los LEMAS nos permiten agrupar las formas flexivas de una palabra y salvar las diferencias derivadas de usos ortográficos particulares, los ARCHILEMAS nos permiten agrupar las distintas variantes del continuum dialectal sefardí, como entre:

<sup>4</sup> Al quitar *-ico* [Columna 1], nos queda la raíz *demašiyad-* por lo que, de acuerdo con la [Columna 2], la regla añade una *-o* antes de buscar en el diccionario *demašiyad*. [Columna 3]: si el diccionario indica que *demašiyad+o* es un adverbio (^RG) entonces, [Columna 4] el conjunto es analizado como adverbio diminutivo (RGD) y se le asigna [Columna 8] el mismo lema que a *demašiyado*; en este caso, DEMASIADO.

<i>faḅló</i>	> FABLAR	> HABLAR
<i>faḅlí</i>	> FABLAR	> HABLAR
<i>haḅló</i>	> HABLAR	> HABLAR
<i>avló</i>	> HABLAR	> HABLAR

en el caso de palabras con flexión, o

<i>que</i>	> QUE	> QUE
<i>ke</i>	> QUE	> QUE
<i>qui</i>	> QUI	> QUE
<i>coe</i>	> COE	> QUE

en el caso de palabras invariables.

Para dichos LEMAS y ARCHILEMAS se ha optado por una representación gráfica sin diacríticos que sigue la del español estándar cuando esta existe. Cuando no existe en español, como en el caso de ciertos préstamos, se ha estandarizado la forma judeoespañola a una de ortografía hispánica por dos motivos:

- (1) para abstraer un lema que represente a todas las formas tanto diacrónicas como dialectales del judeoespañol, y
- (2) para permitir la integración de dicha lematización con otros corpus hispánicos y facilitar así el uso del *CORHIJE* a los hispanistas no sefardistas.

Pero lo cierto es que, al menos en el nivel LEMA, el uso de diacríticos podría ampliar el número de variantes cubiertas por los distintos ARCHILEMAS.

### 2.3. Desambiguación

El modelo probabilístico de *Freeling* que mencionábamos anteriormente está lógicamente ligado a un análisis estadístico previo de las características lingüísticas y de su frecuencia en un corpus determinado. Otra de las ventajas de nuestra adaptación de los recursos de *Freeling* para el español y de su uso sobre un corpus del judeoespañol, es precisamente el aprovechamiento de la ingente información estadística que posee *Freeling* para el español y que utiliza a la hora de desambiguar formas homónimas o de etiquetar las desconocidas, según su contexto sintáctico y sus patrones morfológicos.

Si bien es cierto que entre el español y el judeoespañol hay diferencias tanto sintácticas —por ejemplo, algunas estructuras propias que podríamos asimilar a ciertas «pseudocopulativas» como *Mošé merece matado* (= ‘Mošé merece morir’)— como morfológicas —por ejemplo, formas verbales no personales construidas sobre el tema de perfecto como *quisendo* (vs. esp. *queriendo*) o *tuvido* (vs. esp. *tenido*), o adverbios en *-mente* construidos sobre formas no adjetivales, como *cercamente* (esp. *cercanamente*) o *verdadmente* (esp. *verdaderamente*)—, hay que tener en cuenta que en nuestro plan de actuación, el uso estadístico de *Freeling* se circunscribe a una primera fase de marcación que está siendo manualmente corregida.

De acuerdo con nuestra experiencia previa, entendimos que partir de un corpus previamente analizado y con una alta precisión se consideró preferible a marcar manualmente desde el comienzo cientos de miles de formas desconocidas.

Una vez creados todos los recursos y realizada la adaptación de *Freeling* al judeoespañol, esta se integró en una herramienta propia de análisis textual denominada **CORHIJE-APP** que, partiendo del texto plano de las transcripciones, devuelve un texto en formato XML con toda la información lingüística incorporada, pero que mantiene todas las características textuales de la obra para facilitar su lectura y su posterior presentación en los resultados de las consultas<sup>5</sup>. La herramienta permite de forma muy sencilla incorporar formas desconocidas por *Freeling* (que se señalan en rojo), y revisar tanto los análisis generados automáticamente por las reglas lingüísticas creadas (en azul) como los análisis asignados a formas homónimas potencialmente ambiguas (en verde).



Tal y como hemos señalado anteriormente, la corrección semi-manual de una parte representativa del corpus (en cuanto a distribución geográfica, cronológica, gráfica y de tipología textual) que actualmente estamos llevando a cabo, permitirá establecer un corpus fiable de entrenamiento, con el cual se generarán nuevos modelos probabilísticos que reflejen con mayor exactitud los textos sefardíes y que permitirán a *Freeling* realizar el proceso de desambiguación automática de formas homónimas —con múltiples etiquetas y lemas posibles— y proponer categorías gramaticales para las formas desconocidas.

<sup>5</sup> Desde un punto de vista técnico, usamos: 1) XML y HTML para la representación de los textos y sus marcas, 2) Javascript y Perl para la programación y ejecución de Freeling en el *background* y 3) Sqlite como base de datos.

### 3. CORHIJE 2.0 - EL PROTOTIPO

Tras la lematización, el etiquetado y la desambiguación iniciales del corpus, se ha creado un prototipo de buscador y visualizador de resultados en la web.

The screenshot shows the CORHIJE search interface. At the top, it says "CORHIJE: Corpus Histórico Judeoespañol". Below that, there are search options like "Buscar palabras clave" and "Buscar marcación". A search bar contains the text "MI CORHIJE". Below the search bar, it indicates "Número total de documentos: 32 (Se muestran del 1 al 32)". The main part of the interface is a table with the following columns: IDENTIFICADOR, TÍTULO, LUGAR, FECHA, SIGLO, TIP. TEXTUAL, DESCRIPCIÓN, AUTOR, EDITOR, and PALABRAS. The table lists four documents:

IDENTIFICADOR	TÍTULO	LUGAR	FECHA	SIGLO	TIP. TEXTUAL	DESCRIPCIÓN	AUTOR	EDITOR	PALABRAS
CARTA	[«Carta de Jaïña Ajamán a Abraham Šalom»]	Safed	1550	XVII	Texto en prosa Género tradicional Texto epistolar Original	Carta manuscrita de carácter personal enviada a mediados del siglo XVI de Safed a Alejandría por Jaïña Ajamán, posiblemente el padrastró o un tío del destinatario, Abraham Šalom.	Jaïña Ajamán		509
SEBLA_MHDINA...	«Šeeñá 5 - [Suicidio o asesinato?]»	Salónica	1595	XVI	Texto en prosa Género patrimental Texto narrativo Texto jurídico-administrativo Original	Testimonios en judeoespañol firmados en Bucarest incluidos al comienzo de la <i>Señal</i> número 5 del volumen <i>Šeeñot utšibot... Josef Aamijar de Semmel ben Mošé De Medina</i> , publicado en Salónica en 1595. En ellos se narran las oscuras circunstancias de la muerte de un joven a manos (o no) de aquellos a los que previamente habría robado.	Šemmel ben Mošé De Medina	Abraham Yosef Magdi' bat Sabá'	477
HESEC-2.PROL	<i>Šefér Hésec Šalomó - Prólogo</i>	Venecia	1617	XVII	Texto en prosa Género patrimental Texto didáctico-instructivo Texto bíblico Original	Prólogo judeoespañol de la edición veneciana del glosario bíblico titulado <i>Šefér Hésec Šalomó</i> en el que se narran las circunstancias que propician y justifican la edición de la obra.	Desconocido	Pietro de Lorenzo Bragadin	313
ML-EX1	<i>Relatos del Me'am lo 'eš Šemot I</i>	Constantinopla / Estambul	1733	XVIII	Texto en prosa Género patrimental Texto narrativo Texto didáctico-instructivo Original Traducción/Adaptación	Selección de 85 textos narrativos de carácter ejemplar ( <i>ma asivot y mešalim</i> ) que aparecen insertos en el volumen I del comentario lineal (versículo a versículo) al libro bíblico de Éxodo, obra de Ya'acov Jai' (o Haid) volumen de aparición postuma y que alcanza tan sólo hasta la mitad de la séptima pericopa, «Terumá».	Ya'acov ben Majar Jai' (o Haid)	Yoná ben Ya'acov Askenazi	32439

At the bottom of the interface, it says "CORHIJE" and "e-sefardic | Aitor García Moreno - F. Javier Pueyo Mena".

Este nuevo buscador permite llevar a cabo consultas, simples o combinadas, por forma, lema, archilema y etiqueta gramatical, todas ellas con la posibilidad de introducir comodines. Para la inserción de signos diacríticos —que también pueden ser obviados si se prefiere— el acceso a la caja de búsqueda despliega un teclado virtual con ayudas contextuales en cada caso.

The screenshot shows the CORHIJE search interface with a virtual keyboard. The search bar contains the letter 'd'. Below the search bar, it indicates "Número total de documentos: 32 (Se muestran del 1 al 32)". The table shows the same four documents as in the previous screenshot, but the 'FECHA' column is highlighted in blue for the first document.

Para facilitar la elaboración de las consultas más complejas —sobre todo las referidas a etiquetas gramaticales—, se ha creado un «asistente» por pasos.

The screenshot shows the CORHIJE search interface. At the top, it says "CORHIJE: Corpus Histórico Judeoespañol". Below that, there are navigation tabs for "Consultas", "Mapa", "Resultados", and "Distribución". A search bar contains the query "<en>". The results table shows several entries, with a modal window open over the first row. The modal window has a title "{Etiqueta}/{Lema}/<Archilema>/Forma" and lists options: "Nueva", "Etiqueta", "Lema", "Archilema", and "Forma". The table columns include IDENTIFICADOR, TÍTULO, LUGAR, FECHA, SIGLO, TIP. TEXTUAL, DESCRIPCIÓN, AUTOR, EDITOR, and PALABRAS.

IDENTIFICADOR	TÍTULO	LUGAR	FECHA	SIGLO	TIP. TEXTUAL	DESCRIPCIÓN	AUTOR	EDITOR	PALABRAS
CARTA	[Carta de Jafía Ajumán a Abraham Salom]	Safed	1550	XVII	Texto en prosa Género tradicional	Carta manuscrita de carácter personal enviada a mediados del siglo XVI de Safed a Alejandría por Jafía Ajumán, el padroastro o un tío del destinatario, Abraham	Jafía Ajumán		509
SEELA_MEDINA...	«Šeela 5 - [Suicidio o asesinato?]	Salónica				en judeoespañol firmados en Bucarest incluidos al la Seela número 5 del volumen Seelot utziator ... tar de Semmel ben Moisé De Medina, publicado en 1595. En ellos se narran las oscuras circunstancias de un joven a manos (o no) de aquellos a los que se le robaron.	Semmel ben Moisé De Medina	Abraham Yosef Magda' bat Sabá'	477
HESEC.2.PROL	Še'er Hésec Šelomó - Prólogo	Venecia				de judeoespañol de la edición veneciana del glosario bíblico Še'er Hésec Šelomó en el que se narran las circunstancias que propician y justifican la edición de la obra.	Desconocido	Pietro & Lorenzo Bragadin	313
ML-EX1	Relatos del Me'am lo'et Šemot I	Constantinopla / Estambul	1733	XVIII	Texto en prosa Género patrimonial Texto narrativo Texto didáctico-narrativo Original Traducción/Adaptación	Selección de 85 textos narrativos de carácter ejemplar (ma'asivot y mešalim) que aparecen insertos en el volumen I del comentario lineal (versículo a versículo) al libro bíblico de Éxodo, obra de Ya'acov Ju'í (o Hui), volumen de aparición postuma y que alcanza tan sólo hasta la mitad de la séptima pericopa, «Terumah».	Ya'acov ben Majir Ju'í (o Hui)	Yoná ben Ya'acov Askena'í	32439

Los resultados se presentan en forma de un listado de formas que cumplen las condiciones de la consulta realizada, tal y como vemos en la siguiente búsqueda correspondiente al archilema <EN>:

The screenshot shows the CORHIJE search interface with a frequency table for the archilema <EN>. The table has columns for FRECUENCIA, FORMAS, and DOCUMENTOS. The first row shows a frequency of 4666 for the form "en" across various locations and dates. The second row shows a frequency of 1 for the form "em" in 1877 (Vienna). The third row shows a frequency of 1 for the form "in" in 1935 (Salonica). A total row shows a frequency of 4668.

FRECUENCIA	FORMAS	DOCUMENTOS
4666	en	1550 (Safed), 1595 (Salónica), 1617 (Venecia), 1733 (Constantinopla / Estambul), 1746 (Constantinopla / Estambul), 1765 (Constantinopla / Estambul), 1767 (Constantinopla / Estambul), 1782 (Liorna), 1815 (Kazanlik), 1815 (Viena), 1824 (Tetuán), 1824 (Constantinopla / Estambul), 1859 (Belgrado), 1874 (Sarajevo), 1877 (Viena), 1888 (Adrianópolis / Edirne), 1901 (Sofía), 1902 (Jerusalén), 1903 (Jerusalén), 1904 (El Cairo), 1909 (Madrid), 1922 (Salónica), 1922 (Rustchuk / Ruse), 1922 (Xanthi), 1927 (Nueva York), 1928 (Sofía), 1930 (Constantinopla / Estambul), 1933 (Los Ángeles), 1935 (Salónica), 1935 (Salónica), 1946 (Sofía)
1	em	1877 (Viena)
1	in	1935 (Salónica)
4668	TOTAL	

Una vez seleccionada una de las formas propuestas (*en/em/in*), se presenta un listado contextual de la misma (KWIC) con todos los ejemplos encontrados en el corpus, como se muestra en la siguiente figura:

DOCUMENTO	FECHA	LUGAR	CONTEXTO PRECEDENTE	FORMA	CONTEXTO SIGUIENTE
CARTA (h. 1r)	1550	Safed	vos torno a rogar que no mos echés en alovido Ansi viyan los niños y que mos mandés dos letras	en	todo modo Y ya agora baru H' caso yuestra hermana vos rogo que mirés por mi mortaja y me mandades
SEELA_MEDINA-3.5 (h. 1)	1595	Salónica	Šeelá 5 Por encunto nos hallamos aquí	en	București los firmados abajo y yino h' r Abraham b' r Eli ézer yŠ' y y dio 'edut cómo de una yan torbá que se robó de la botiga de h' r Yishac Rufus y de h' r Habib Amato que el balur h' r Yuda Rufus yŠ' y tenia en ella como 4 mil as-pros y de la compañía de h' r Yishac Rufus y h' r Habib Amato mil y 600
SEELA_MEDINA-3.5 (h. 1)	1595	Salónica	de la botiga de h' r Yishac Rufus y de h' r Habib Amato que el balur h' r Yuda Rufus yŠ' y tenia	en	ella como 4 mil aspros y de la compañía de h' r Yishac Rufus y h' r Habib Amato mil y 600
SEELA_MEDINA-3.5 (h. 1)	1595	Salónica	Yuda Rufus yŠ' y tenia	en	la botiga de h' r Habib dicho y fallaron allí a rebi Ya acob bar Habib yŠ' y y le dijeron mirad de
SEELA_MEDINA-3.5 (h. 1)	1595	Salónica	Yuda Rufus yŠ' y tenia	en	la botiga de h' r Habib dicho y que rebi Ya acob bar Habib dicho le rogó por amor de el Dio
SEELA_MEDINA-3.5 (h. 1)	1595	Salónica	Yuda Rufus yŠ' y tenia	en	București y nos amostró una casa onde dijeron que se había ahorcado el mozo por lo cual la fumos a
HESEC-2.PROL (h. 2v)	1617	Venecia	estampar viendo el amancamiento que ha manceado la mesa lingua hebraica llamada de mesos sabios laón hacodes por ser la lingua	en	que fue dada mesa Ley Santa más en meso tiempo que en los tiempos pasados lo cual es cayša de
HESEC-2.PROL (h. 2v)	1617	Venecia	mesa lingua hebraica llamada de mesos sabios laón hacodes por ser la lingua en que fue dada mesa Ley Santa más	en	meso tiempo que en los tiempos pasados lo cual es cayša de no ser entendida mesa Ley Santa y yimos
HESEC-2.PROL (h. 2v)	1617	Venecia	de mesos sabios laón hacodes por ser la lingua en que fue dada mesa Ley Santa más en meso tiempo que	en	los tiempos pasados lo cual es cayša de no ser entendida mesa Ley Santa y yimos que mesos sabios dieron
HESEC-2.PROL (h. 2v)	1617	Venecia	cual es cayša de no ser entendida mesa Ley Santa y yimos que mesos sabios dieron licencia que se escribiese	en	grego que era la más prefecta y más usada en aquel tiempo de modo que siendo la lingua española la
HESEC-2.PROL (h. 2v)	1617	Venecia	y yimos que mesos sabios dieron licencia que se escribiese en grego que era la más prefecta y más usada	en	aquel tiempo de modo que siendo la lingua española la más usada en meso tiempo cierto será dada la misma
HESEC-2.PROL (h. 2v)	1617	Venecia	era la más prefecta y más usada en aquel tiempo de modo que siendo la lingua española la más usada	en	meso tiempo cierto será dada la misma licencia para la lingua dicha Y los años pasados en Saloniqui y en
HESEC-2.PROL (h. 2v)	1617	Venecia	la más usada en meso tiempo cierto será dada la misma licencia para la lingua dicha Y los años pasados	en	Saloniqui y en Constantina se escomezo a estampar una gran parte de la micrá todo el pasuc: en hebraico y
HESEC-2.PROL (h. 2v)	1617	Venecia	en meso tiempo cierto será dada la misma licencia para la lingua dicha Y los	en	Constantina se escomezo a estampar una gran parte de la micrá todo el

siendo posible también consultar el texto completo correspondiente a cada ejemplo para su mayor contextualización o para cotejarlo inmediatamente con el facsímil:

«SEELÁ 5 - [SUICIDIO O ASESINATO?]»

1

[+] [Seelá 5]

... «Por encunto nos hallamos aquí en București los firmados<sup>o</sup> abajo<sup>o</sup>, y yino h' r Abraham b' r Eli ézer, yŠ' y, y dio 'edut cómo de una yan torbá que se robó de la botiga de h' r Yishac Rufus y de h' r Habib Amato, que el balur h' r Yuda Rufus, yŠ' y, tenia en ella como 4 mil as-pros y de la compañía de h' r Yishac Rufus y h' r Habib Amato mil y 600 as-pros, que le atorgó el muchacho<sup>o</sup> Yehudá bar Gueršón que la había robado<sup>o</sup> él.

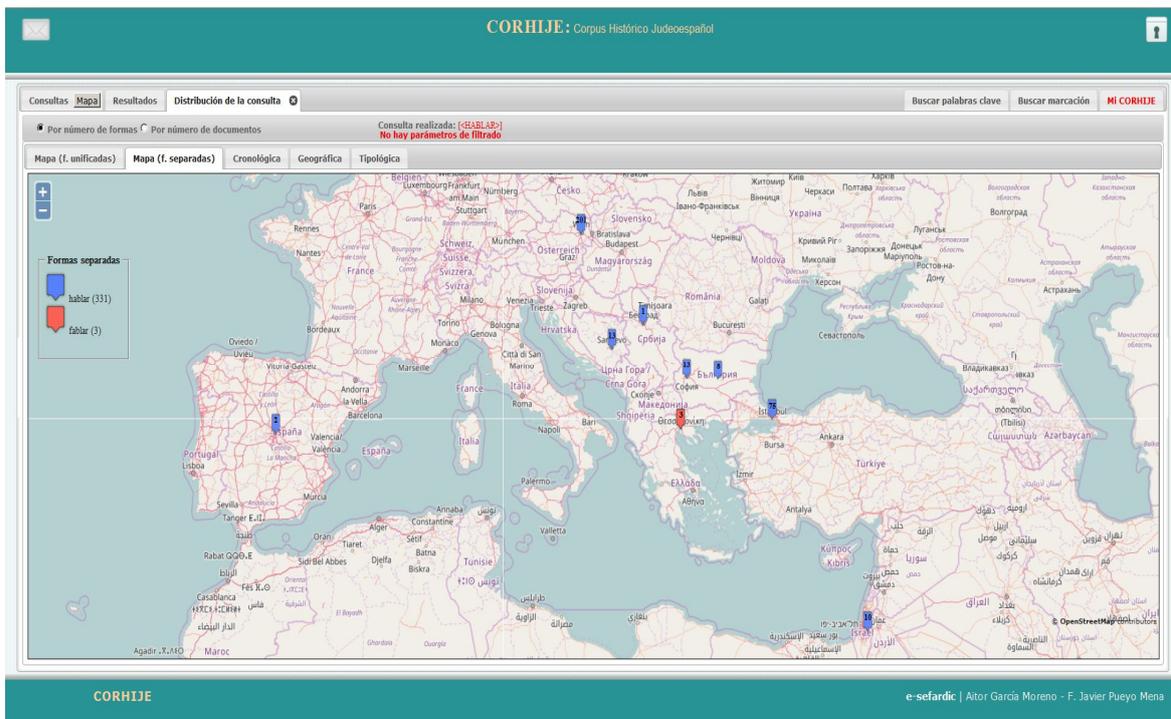
» Y mañana de alhad yino hana' alá h' r Dayid yŠ' y, y fue<sup>o</sup> a rebi Abraham bar Eli ézer dicho: "Yamos a esos mozos y les digamos que abaste, que se dejen", que no se siga algún daño d'ello: que no se tornase turco o ficiese algún mal de sí.

» Y fueron<sup>o</sup> los señores dichos en la botiga de h' r Habib dicho y fallaron allí a rebi Ya acob bar Habib, yŠ' y, y le dijeron "mirad de sacar a ese muchacho antes que acontezca algún mal"; y les respondió h' r Ya acob bar Habib dicho "por amor de el Dio que fuesen a rebi Yehudá Rufus, yŠ' y, y a rebi Yosef Rufus y les dijese<sup>o</sup> que se dejen y que abasta ya". Y rebi Yehudá Rufus dicho le empujó a rebi Abraham bar Eli ézer dicho: "¿Para esto yimistes aquí? ¿Para hacer šemata?". Y se fueron<sup>o</sup> y cerraron la puerta el dicho k' r Yuda y Yosef Rufus y se fueron<sup>o</sup>.

Este 'edut es de h' r Abraham Eli ézer, y el na alá h' r Dayid ben Osa dicho dice el mismo 'edut, si non que se asentó en la botiga de h' r Habib dicho y que rebi Ya acob bar Habib dicho le rogó por amor de el Dio y llamó a rebi Abraham bar Eli ézer, y irés a esos mancebos y les dirés que lo dejen a el muchacho, que no aconteza algún desastre. Y quedó allí el mancebo el mešaret el día y la noche, y la mañana amaneció muerto. Dicen los dichos h' r Yuda y h' r Yosef dichos, que el mismo se ahorcó, yecayam.

Yishac Šebi Baruj Galiappa Baruj bajar Eliyá Mošé Anġel 'edu-t> aler: «Por encunto nos llamó h' r Habib Amato en București y nos amostró una casa onde dijeron que se había ahorcado el mozo, por lo cual la fumos a yer el na alá h' r Dayid Osa y su hermano h' r Abraham Osa y h' r Dayid mar Hayim, y yimos cómo el tavan<sup>o</sup> de aquella casa estaba enbarrado encima, y por debajo estaban de tal modo los maderos y las tablas que no había modo de se poder poner cuerda; y cuanta m[aj]s que aquella noche que faleció el mozo supimos de cierto que durmieron dentro aquella casa con el muchacho h' r Semu el Esetrelichá yeh' r Yuda Rufus yeh' r Yosef Rufus dichos arriba. Y por haber pasado esto delante nosotros, firmamos aquí Mošé Anġel Dayid mar Hayim».

Asimismo, los resultados pueden ser proyectados en mapas, como en el siguiente ejemplo de las distintas formas documentadas del archilema <HABLAR>, con la opción de agrupación *por lemas* (*hablar/fablar*) en lugar de la opción por defecto que es la agrupación *por formas* (*avló/hablí/fablaremos*, etc.):



Al mismo tiempo se generan gráficas estadísticas de distintos tipos, como la que puede observarse en el siguiente ejemplo, que corresponde al progresivo abandono del uso de <v> *vav* para /v/ en formas romances actualmente notadas con <b> en judeoespañol:



Funcionalidades —algunas de ellas todavía en desarrollo—, que, junto a la implementación completa del visor de documentos con la versatilidad ya probada en *CORHIJE* 1.0, habrán de ocupar nuestro tiempo, al menos, hasta la próxima edición de *CODILI*.

Entre tanto, confiamos en que nuestro sistema de *doble lematización* inspire a todos aquellos corpus lingüísticos —sea cual sea su orientación— donde la variación desempeña un papel especialmente destacado; pues entendemos que el establecimiento de distintos niveles de agrupación (ya sea formal, como en nuestro caso, o de otro tipo) permite dar un mejor y más variado tratamiento a los datos lingüísticos que cada corpus maneja.

#### REFERENCIAS BIBLIOGRÁFICAS

- GARCÍA MORENO, Aitor (dir.) (2008-2017): *Diccionario Histórico del Judeoespañol (DHJE)*. <http://www.esefardic.es/dhje> [Consulta: 30/6/2017]
- GARCÍA MORENO, Aitor y Francisco Javier PUEYO MENA (2013-2017): *Corpus Histórico Judeoespañol (CORHIJE)*. <http://www.esefardic.es/corhije> [Consulta: 30/6/2017]
- HASSÁN, Iacob (1978): «Transcripción normalizada de textos judeoespañoles», *Estudios Sefardíes*, 1, pp. 147-150.
- PADRÓ, Lluís (2011): «Analizadores Multilingües en FreeLing», *Linguamática*, 3, 2, pp. 13-20. <http://www.linguamatica.com/index.php/linguamatica/article/view/115> [Consulta: 1/8/2017]
- SÁNCHEZ MARCO, Cristina, Gemma BOLEDA and Lluís PADRÓ (2011): «Extending the Tool, or How to Annotate Historical Language Varieties», in *Proceedings of the 5<sup>th</sup> ACL-HLT Workshop on Language Technology for Cultural Heritage, Social Sciences, and Humanities*. Stroudsburg (PA): Association for Computational Linguistics, pp. 1-9. <http://dl.acm.org/citation.cfm?id=2107637&CFID=979433322&CFTOKEN=43121501> [Consulta: 1/8/2017]