

Detección del alcance de las negaciones en español usando Conditional Random Fields

Antonio Tamayo, Jason Angel, Alexander Gelbukh

Instituto Politécnico Nacional (IPN),
Centro de Investigación en Computación (CIC),
Ciudad de México, México

{ajtamayoh, ajason08}@gmail.com, www.gelbukh.com

Resumen. Detectar automáticamente el alcance de las negaciones en los textos es un tema de mucha importancia para varias tareas del procesamiento de lenguaje natural como el análisis de sentimientos, la recuperación de información y la extracción de información. El presente trabajo propone un enfoque híbrido basado en el modelo Conditional Random Fields con características sintácticas y el uso de reglas del mismo tipo para resolver el problema del alcance de las negaciones en un corpus de reseñas de películas, libros y productos escritas en español. El sistema propuesto alcanza 0,77 en la medida Macro-F1 para esta tarea, superando a un fuerte baseline que obtuvo 0,73.

Palabras clave: Alcance de la negación, Conditional Random Fields, reglas sintácticas.

Negation Scope Detection in Spanish Using Conditional Random Fields

Abstract. Automatic detection of negation scopes in texts is a relevant topic for various natural language processing tasks such as sentiment analysis, information retrieval and information extraction. This work presents a hybrid approach based on the model called Conditional Random Fields, using both syntactic features and rules to solve the negation scope detection issue in a corpus of films, books and products reviews written in Spanish. The system proposed achieved 0.77 Macro-F1, overcoming a strong baseline which obtains 0.73 for the same task.

Keywords: Negation scope, Conditional Random Fields, syntactic rules.

1. Introducción

La negación es un fenómeno lingüístico mediante el cual se invierte el valor de verdad de la unidad lingüística (proposición, sintagma o palabra) a la que se aplica [1]; sin embargo, hay palabras que en determinados contextos funcionan como indicadores de negación, pero en otros, no niengan o funcionan como indicadores de contraste o de comparación. Para analizar este fenómeno es necesario definir los siguientes dos aspectos fundamentales: a) el indicador de negación y b) el alcance (también llamado ámbito o dominio en algunos casos) de dicho indicador. También se suele hacer énfasis en el foco, que se refiere a la palabra o sintagma dentro del alcance que se niega explícitamente, y al evento, que se refiere al proceso, acción o estado afectado por la negación. En la figura 1, se muestra un ejemplo de una oración con presencia de negación, con su indicador, alcance y evento debidamente marcados.

```
<sentence>
  A veces enfría cuando hay que calentar, a veces falla el motor de la ventilación forzada y
  <neg_structure>
    <scope>
      <negexp>
        no
      </negexp>
      <event>
        puedo desempañar
      </event>
      el cristal delantero
    </scope>
  </neg_structure>
  ;
</sentence>
```

Fig. 1. Ejemplo de negación con alcance y evento marcados.

La importancia de determinar automáticamente el alcance de las negaciones ha sido evidenciada en múltiples tareas como: extracción de información [2], traducción automática [3], análisis de sentimientos [?,5,6], entre otros. Sin embargo, esta no es una tarea sencilla, ya que presenta retos considerables al interactuar con otros fenómenos lingüísticos, requiriendo un análisis textual profundo para su tratamiento [7]. Entre estos retos se encuentra la dependencia de la lengua del texto o del dominio del mismo; esto no es un aspecto menor, puesto que “el carácter idiosincrático de la expresión de la negación en cada lengua requiere un análisis lingüístico específico” [1]. También son retos los casos de negaciones anidadas y la dependencia de una correcta marcación previa de los indicadores de negación; esto último con sus propios escollos, ya que un indicador puede tener diferentes categorías gramaticales, puede encontrarse a nivel sintáctico, léxico o morfológico y puede ser de una palabra o de varias (incluso discontinuas). Adicionalmente, en la negación se puede presentar gradación (con incrementadores y decrementadores), negaciones comparativas (i.e., ... no es todo lo ...), frases hechas que expresan negación (i.e., ni lo sueñes) o estructuras negativas que no expresan negación (i.e., no me iré hasta no verte). Además, en el español se encuentran negaciones reforzadas mediante otras partículas de negación [1]. Por

ejemplo:

Mi coche, marca Chevy, es genial, **no** me ha fallado **jamás**.

En este trabajo se presentan dos modelos para marcar alcance de las negaciones, en un conjunto de datos de reseñas de películas, libros y productos escritos en español. El primero es un clasificador que utiliza una regla de puntuación simple, y se toma como *baseline*; el segundo es nuestra propuesta, un modelo basado en *Conditional Random Fields* (CRF) más un procesamiento posterior sencillo usando patrones morfosintácticos.

Este artículo está organizado de la siguiente forma: la sección 2 muestra los trabajos similares al nuestro tanto en español como en inglés. En la sección 3 se encuentra la descripción del conjunto de datos usado para en este trabajo. Los experimentos realizados son presentados en la sección 4. La sección 5 muestra los resultados encontrados y el análisis de los mismos. Finalmente, en la sección 6 se presentan las conclusiones y el trabajo futuro en la línea de investigación concerniente a la detección del alcance de las negaciones.

2. Trabajos relacionados

La detección del alcance de la negación ha sido bien explorada en el idioma inglés, sin embargo, existen muy pocos trabajos para el español, pese a ser la segunda lengua con mayor número de hablantes en el mundo¹. Mencionaremos aquí los principales trabajos llevados a cabo para solucionar esta tarea, desde cuatro enfoques: aplicación de reglas, usando aprendizaje automático supervisado con modelos clásicos, híbridos entre los dos anteriores y usando aprendizaje profundo.

2.1. Enfoque basado en reglas

El trabajo de Martí et al. (2016) [1], es un referente en cuanto a la definición y el análisis de los diferentes patrones de negación y su tipología en español. De igual manera lo es, el trabajo realizado alrededor de la negación y sus alcances, por Cotik et al. (2016) [8], en el que se implementan diferentes algoritmos para detectar si un término de interés se encuentra dentro del alcance de una negación en el dominio de la radiología, para lo cual usaron características sintácticas como categorías gramaticales, árboles sintácticos y de dependencia y una adaptación del sistema NegEx basado en reglas, propuesto por Chapman et al. (2001) [9]. Por su parte, el trabajo de Jimenez-Zafra et al. (2018) [10], representa una contribución muy importante para los avances en los estudios de la negación en español, por su trabajo de anotación de un corpus en 8 diferentes dominios con sus negaciones, sus respectivos alcances y otras características importantes de este fenómeno, y que además fue adaptado para analizar el rol de la negación en

¹ Fuente: <https://www.ethnologue.com/>

el análisis de sentimientos en español. Para el inglés, cabe destacar los trabajos de Gindl et al. (2008) [11] con su método llamado *NegHunter* para detectar conceptos negados en documentos clínicos; Harkema et al. (2009) [12] con el algoritmo llamado *ConText* para determinar condiciones clínicas negadas dentro de reportes clínicos; Apostolova et al. (2011) [13], quienes propusieron un sistema llamado *ScopeFinder*, basado en reglas y patrones léxico-sintácticos extraídos automáticamente, para detectar el alcance de las negaciones y especulaciones en el corpus Bioscope [14]; Ballesteros et al. (2012), quienes introdujeron el análisis de dependencia y el sintáctico, mostrando sus capacidades para la detección de la negación; y finalmente, Mehrabi et al. (2015), quienes desarrollaron el algoritmo DEEPEN, el cual incorpora relaciones de dependencia al sistema NegEx [9], para detectar negaciones en textos clínicos.

2.2. Enfoque basado en aprendizaje automático clásico

La tarea de detectar las negaciones y sus alcances en un texto también ha sido abordada usando aprendizaje automático supervisado con modelos clásicos. En esta línea se destacan los trabajos de Rokach et al. (2008) [15], quienes usaron una arquitectura de clasificadores en cascada con árboles de decisión, Morante et al. (2008) [16], Morante y Daelemans (2009) [17], Cruz et al. (2012) [18] y Wu et al. (2014) [19], los cuales combinaron diferentes modelos de aprendizaje automático, Councill et al. (2010) [20], con su sistema basado en CRF, indicadores de negación y dependencia sintáctica, Agarwal y Yu (2010) [21], también usando CRF, Zhu et al. (2010) [22], con su trabajo de análisis semántico, en el cual los indicadores de negación son tratados como predicados y sus alcances como los argumentos de dichos indicadores, Zou et al. (2013) [23] y Shivade et al. (2015) [24], con sus sistemas basados en kernel y características sintácticas, Cruz et al. (2016) [4] y Attardi et al. (2015) [25], quienes usaron árboles de dependencia sintáctica.

2.3. Enfoque híbrido entre aprendizaje automático clásico y reglas

Goryachev et al. (2006) [26] fueron los primeros en probar sistemas combinando reglas con modelos como Naïve Bayes y máquinas de vectores de soporte (SVM, por sus siglas en inglés), modificando el sistema NegEx [9], sin conseguir buenos resultados. También se destacan los trabajos de Huang y Lowe (2007) [27], combinando expresiones regulares y análisis gramatical, Fujikawa et al. (2013) [28], con el sistema llamado *NegFinder*, que combina métodos estadísticos y heurísticos, White (2012) [29], quienes usaron el modelo *Conditional Random Field* (CRF) y expresiones regulares, así como Gyawali y Solorio (2012) [30] que usaron Máquinas de Vectores de Soporte y expresiones regulares, Reitan et al. (2015) [5], usaron CRF y una lista de indicadores de negación, y Pröllochs et al. (2017) [31], quienes propusieron una novedosa estrategia basada en aprendizaje por refuerzo.

2.4. Enfoque basado en aprendizaje profundo

Los avances de los últimos años en el área del aprendizaje profundo para procesamiento de lenguaje natural, se han aplicado para la detección de las negaciones y sus alcances. Entre los trabajos más relevantes se encuentran los de Fancellu et al. (2016) [32], quienes probaron las arquitecturas de perceptrón multicapa y LSTM bidireccional, Qian et al. (2016) [33], con su enfoque basado en redes neuronales convolucionales, Lazib et al. (2016) [34], con su método basado en redes neuronales recurrentes, Fei et al. (2020) [35], con su sofisticada arquitectura que combina redes neuronales recursivas y CRF en su capa de predicción, y finalmente, Fabregat et al. (2019) [36], quienes trabajaron con el mismo conjunto de datos del presente trabajo, con una arquitectura que combina redes convolucionales y LSTM, alcanzando 0,72 en la medida F1 (no especifican si micro-F1 o macro-F1) para detección del alcance de las negaciones a nivel de token.

3. Conjunto de datos de entrenamiento

El presente trabajo fue realizado usando el corpus SFU Review SP-NEG [10], proporcionado para la tarea B de las competencias NEGES 2018 [37] y NEGES 2019 [38]. Dicha tarea no consistió en detectar el alcance de las negaciones, sino determinar su influencia en el problema de análisis de sentimientos. No obstante, el conjunto de datos cuenta con 3,078 oraciones, cada una de las cuales está marcada con sus respectivos indicadores de negación y sus alcances, facilitando así su uso para el trabajo propuesto en este artículo. Siguiendo con la mecánica de la competencia NEGES, para este trabajo se conservó la partición del conjunto de datos en: a) entrenamiento, b) desarrollo y c) validación. En la tabla 1, se observa la distribución de las oraciones con negación para las tres particiones por dominio.

Tabla 1. Cantidad de oraciones con negación en el conjunto de datos por dominio.

Dominio	Entrenamiento	Desarrollo	Validación
Coches	175	37	48
Hoteles	187	51	46
Lavadoras	183	31	61
Libros	312	111	219
Móviles	224	75	40
Música	192	25	63
Computadoras	118	39	73
Películas	523	88	157
Total	1914	457	707

El conjunto de datos se encuentra en formato XML; para nuestro trabajo se realizó un preprocesamiento, ya que para detectar el alcance de las negaciones

se usó el esquema BIO [39], *begin* (B), *inside* (I), *outside* (O), para marcar la unidad léxica que determina el inicio del alcance de un indicador de negación (B), la(s) unidad(es) léxica(s) dentro de dicho alcance (I) y las que están fuera del alcance de algún indicador de negación (O). Hay que precisar que las negaciones presentan retos como: a) múltiples instancias de negación (indicadores), b) alcances de negación anidados y c) alcances discontinuos. En el presente trabajo, se tiene en cuenta el primero, pero no el segundo ni el tercero. En el siguiente ejemplo se ilustra el esquema de representación usado:

pero “ el orfanato ” no te engancha , ni consigue intrigar y mucho menos dar miedo .

[O, O, O, O, O, B, I, I, O, B, I, I, O, B, I, I, O]

4. Experimentos

4.1. Baseline

El siguiente *baseline* se definió como punto de partida para marcar el alcance de las negaciones:

El alcance inicia a partir de la aparición del indicador de negación (o si es multipalabra, a partir de la aparición de su primera palabra) y va hasta la unidad léxica que está inmediatamente antes del primer signo de puntuación que se encuentre (de izquierda a derecha en el texto). Veamos un ejemplo:

“vamos, por 11900 euros yo no me lo compraba.”

[O, O, O, O, O, O, B, I, I, I, O]

En este ejemplo, el indicador de negación es la palabra “no”, por lo tanto, el *baseline* la marca con 'B' y a las palabras “me”, “lo” y “compraba”, las marca con 'I'.

4.2. Modelo

El modelo propuesto es *Conditional Random Fields* [40] (CRF), el cual fue entrenado usando características lingüísticas y la siguiente configuración:

Características: En la tabla 2 se observa el nombre, el tipo y la descripción de las características usadas para entrenar el modelo CRF.

Todas las características descritas en la tabla 2, fueron extraídas usando la librería SpaCy³. Es importante aclarar que estas características se encuentran definidas a nivel de palabra (o unidad léxica), por lo tanto, cada oración del

³ <https://spacy.io/api/token>

Tabla 2. Características usadas para el entrenamiento del modelo CRF.

Característica	Tipo	Descripción
Forma	cadena de texto	La palabra tal como aparece en el texto
Lemma	cadena de texto	La palabra como aparece en los diccionarios
Part-of-Speech	cadena de texto	Categoría gramatical de la palabra
is_cue	buleana	Marca si es un indicador de negación o no ²
ancestors	cadena de texto	Secuencia de descendientes sintácticos
rights	cadena de texto	Los hijos inmediatos a la derecha, en el análisis de dependencia sintáctica
head	cadena de texto	El padre sintáctico de la palabra
r_edge	cadena de texto	El descendiente sintáctico más a la derecha
l_edge	cadena de texto	El descendiente sintáctico más a la izquierda
dep_	cadena de texto	Relación de dependencia sintáctica
indice	númerica	Posición de la palabra en la oración
is_punct	buleana	Marca si es un signo de puntuación o no
is_sent_start	buleana	Marca si es el inicio de la oración o no
subtree	cadena de texto	Secuencia que incluye a la palabra y a todos sus descendientes sintácticos

²La palabra se marca como negación si está dentro de la siguiente lista: [apenas, nada, sin, a_falta.de, ninguno, no_solo, no, ni, ninguna, ningún].

conjunto de datos fue representada como una lista de diccionarios en Python, donde cada diccionario representa una unidad léxica y contiene las 14 características previamente descritas, y cada lista representa una oración y contiene tantos diccionarios como unidades léxicas tiene la oración.

Se realizaron múltiples combinaciones de estas características para finalmente determinar este conjunto como el que mejor representaba los datos para solucionar la tarea. Además, se probaron otras características como la representación de las palabras usando los *word embeddings* de SpaCy y la norma de dichos vectores, pero estas no aportaron información relevante, o empeoraban los resultados.

Configuración: El modelo CRF fue implementado usando la librería `sklearn-crfsuite`⁴ con los siguientes parámetros:

$c_1 = 0,9$; $c_2 = 0,03$; *iteraciones* = 60; *todas_las_posibles_transiciones* = *True*

4.3. Procesamiento posterior

Este procesamiento consistió en aplicar reglas sintácticas a la salida entregada por el modelo CRF, las cuales son descritas mediante el siguiente algoritmo:

⁴ <https://sklearn-crfsuite.readthedocs.io/en/latest/>

```

para cada oración hacer
  |
  |  $i = 0;$ 
  | para cada unidad léxica hacer
  | |
  | | si la unidad léxica en  $i$  está marcada con  $B$  entonces
  | | |
  | | | si se encuentra ADP-DET-(NOUN o PRON) desde  $i - 3$ 
  | | | entonces
  | | | | corregir la salida con: [B, I, I, I] desde la posición  $i - 3;$ 
  | | | fin
  | | | si si se encuentra DET-NOUN-ADJ desde  $i - 3$  entonces
  | | | | corregir la salida con: [B, I, I, I] desde la posición  $i - 3;$ 
  | | | fin
  | | | si si se encuentra DET-(NOUN o PRON) desde  $i - 2$ 
  | | | entonces
  | | | | corregir la salida con: [B, I, I] desde la posición  $i - 2;$ 
  | | | fin
  | | | fin
  | |  $i = i + 1$ 
  | fin
fin

```

Algoritmo 1: Procesamiento posterior.

Con, ADP: preposición; DET: determinante; NOUN: nombre; PRON: pronombre y ADJ: adjetivo.

Aplicando estas reglas a la salida del modelo CRF, se consigue expandir el alcance de las negaciones hacia la izquierda, corrigiendo el inicio del mismo e incluyendo tokens del alcance no detectados por el modelo. Esto es, cuando en la salida del modelo se detecta una unidad léxica marcada con B, se valida si las tres unidades léxicas anteriores presentan alguno de los siguiente patrones morfosintácticos (de izquierda a derecha): ADP-DET-(NOUN o PRON), DET-NOUN-ADJ o DET-(NOUN o PRON); la validación se hace en ese orden, y en caso de cumplirse, se sobrescriben con [B, I, I, I], las posiciones desde $i - 3$ hasta i de la dicha salida, para los dos primeros patrones, y con [B, I, I], las posiciones desde $i - 2$ hasta i , para el último patrón.

5. Resultados y análisis

Para medir los resultados en el alcance de las negaciones se usaron las medidas *Macro-precision* (Pr.), *Macro-recall* (Rec.) y Macro-F1, determinando la clasificación correcta a nivel de palabra (token). Es decir, marcando el número de palabras clasificadas correctamente como parte del alcance de la negación o fuera de él.

En la tabla 3 y en la tabla 4, se observan los resultados obtenidos en la detección de los alcances de la negación usando el conjunto de datos de desarrollo

y validación respectivamente, para el *baseline*, el modelo CRF y CRF extendido con el procesamiento posterior usando reglas sintácticas.

Tabla 3. Resultados en el conjunto de datos de desarrollo.

Dominio	Baseline			CRF			CRF + Reglas		
	Pr.	Rec.	F1	Pr.	Rec.	F1	Pr.	Rec.	F1
Coches	0.68	0.78	0.72	0.75	0.73	0.74	0.73	0.72	0.72
Hoteles	0.66	0.76	0.70	0.83	0.73	0.77	0.81	0.73	0.76
Lavadoras	0.73	0.87	0.78	0.78	0.70	0.74	0.77	0.70	0.73
Libros	0.69	0.79	0.73	0.76	0.72	0.74	0.78	0.74	0.76
Móviles	0.78	0.87	0.81	0.82	0.76	0.78	0.78	0.74	0.75
Música	0.64	0.71	0.67	0.76	0.73	0.74	0.76	0.74	0.75
Ordenadores	0.66	0.73	0.69	0.74	0.69	0.71	0.75	0.71	0.73
Películas	0.71	0.81	0.75	0.81	0.74	0.77	0.83	0.76	0.79
Promedio	0.69	0.79	0.73	0.78	0.73	0.75	0.78	0.73	0.75

Tabla 4. Resultados en el conjunto de datos de validación.

Dominio	Baseline			CRF			CRF + Reglas		
	Pr.	Rec.	F1	Pr.	Rec.	F1	Pr.	Rec.	F1
Coches	0.70	0.75	0.72	0.75	0.69	0.72	0.74	0.70	0.72
Hoteles	0.63	0.72	0.66	0.78	0.70	0.74	0.79	0.72	0.75
Lavadoras	0.71	0.81	0.75	0.83	0.77	0.79	0.85	0.80	0.82
Libros	0.66	0.74	0.69	0.77	0.73	0.75	0.80	0.76	0.78
Moviles	0.75	0.88	0.80	0.80	0.80	0.80	0.79	0.879	0.79
Musica	0.68	0.78	0.72	0.72	0.71	0.71	0.73	0.72	0.73
Ordenadores	0.68	0.78	0.72	0.79	0.72	0.75	0.82	0.75	0.78
Peliculas	0.70	0.79	0.74	0.81	0.73	0.76	0.82	0.76	0.79
Promedio	0.69	0.78	0.73	0.78	0.73	0.75	0.79	0.76	0.77

Como se mencionó en la sección de experimentos (sección 4), el uso de los *word embeddings* de SpaCy, no aportó información relevante a nuestro modelo. Por el contrario, las características sintácticas sí aportaron dicha información y ayudan al modelo a resolver el problema de mejor manera. Encontramos además, que nuestro modelo CRF algunas veces no detecta correctamente el inicio de los alcances de las negaciones y en otros casos también corta el alcance mucho antes de lo debido. La primera limitación fue mitigada usando las tres reglas sintácticas definidas en el algoritmo 1, en la sección 4.3. Estas reglas fueron diseñadas analizando los patrones morfosintácticos encontrados en las muestras del conjunto de datos para las cuales el modelo cometía errores. A continuación se muestra un ejemplo para ilustrar esta situación:

Antonio Tamayo, Jason Angel, Alexander Gelbukh

hay que decir también que el ordenador no viene con el cd de el sistema operativo , sino éste está preinstalado .

Salida correcta:

[O, O, O, O, O, O, B, I, I, I, I, I, I, I, I, I, O, O, O, O, O, O]

Salida de CRF:

[O, O, O, O, O, O, O, O, B, I, I, I, I, I, I, I, I, O, O, O, O, O, O]

Salida de CRF + Reglas:

[O, O, O, O, O, O, B, I, I, I, I, I, I, I, I, I, O, O, O, O, O, O]

En el ejemplo anterior, el procesamiento posterior corrige el alcance de la negación al identificar el patrón DET-NOUN.

El segundo problema realmente no es fácil de corregir a partir de reglas, puesto que no se identificó ninguna regularidad sintáctica que permitiera expandir los alcances identificados por el modelo y de esa forma mejorar los resultados. Se probó haciendo la expansión de los alcances identificados por el modelo hasta dónde se encontrara el primer signo de puntuación, emulando al *baseline*, pero esto empeoró los resultados.

Al observar los resultados bajo la medida *recall*, se aprecia que la mayor dificultad de nuestro modelo consiste en cortar los alcances de la negación antes de encontrar la unidad léxica que cierra dichos alcances, redundando en la aparición de falsos negativos e impidiéndole superar al *baseline* en esta medida y así poder presentar un mejor resultado en la medida macro-F1. Esto se aprecia claramente en el siguiente ejemplo:

de el cassette también se rompio ellector a los 6 meses y no lo cubre la garantia .

Salida correcta:

[O, O, B, I, I, I, I, O]

Salida de CRF + Reglas:

[O, O, B, I, I, O, O, O]

Salida del *baseline*:

[O, O, B, I, I, I, I, O]

No obstante, aún bajo las limitaciones mencionadas, nuestros modelos empleando CRF superaron al *baseline* en todos los dominios, excepto en coches y móviles. Esto ocurre porque en estos dominios en particular, la puntuación es un rasgo que permite marcar el alcance de las negaciones con mayor precisión que en los demás dominios, haciendo que la regla en la cual está basado el *baseline*, entregue mejores resultados que el modelo propuesto. Particularmente el modelo extendido con reglas supera al *baseline*, en al menos un 5%, en la mayoría de los dominios, bajo la medida Macro-F1. Notamos además que el empleo de reglas que extiende las capacidades del CRF mejora, o mantiene sus resultados para todos los dominios, a excepción de móviles.

Finalmente, se resalta que nuestro modelo supera en un 5% en la clasificación a nivel de token⁵, al modelo basado en aprendizaje profundo, propuesto por Fabregat et al. (2019) [36], el único trabajo realizado para alcance de las negaciones en español y que usa el mismo conjunto de datos que usamos en el presente trabajo.

6. Conclusiones y trabajo futuro

En este trabajo presentamos un enfoque para detectar el alcance de las negaciones en español. Para ello empleamos un conjunto de datos de reseñas de películas, libros y productos, un campo que ha sido muy poco explorado en la comunidad científica. Se estableció un simple pero fuerte *baseline*, basado en una regla de puntuación, y que mejora los resultados del trabajo que se puede considerar el estado del arte en esta tarea [36]. Se propuso un modelo que combina Conditional Random Fields con características sintácticas, logrando mejorar en un 4% los resultados obtenidos por el *baseline*, en el conjunto de datos de validación. Nuestro trabajo permitió establecer la importancia de los patrones morfosintácticos, al combinarlos con el clasificador CRF. Finalmente, cabe mencionar la contribución de este trabajo para el español, la segunda lengua con mayor número de hablantes en el mundo, y para la que se ha explorado muy poco en la detección del alcance de las negaciones, cuyas aplicaciones son muy relevantes para diferentes tareas del procesamiento de lenguaje natural.

Como trabajo futuro se planea realizar una explotación enfatizada en características (patrones) morfosintácticas, las cuales parecen ser altamente discriminantes en detectar el alcance de la negación.

Se proyecta además, fusionar nuestro modelo CRF con modelos de aprendizaje profundo capaces de reconocer otros patrones inherentes al comportamiento de los alcances de la negación en español.

De igual manera, se abre la puerta para aplicar el modelo presentado en este trabajo en tareas como la extracción de información en dominios tan importantes

⁵ Asumiendo que Fabregat et al. (2019) usaron la medida macro-F1, puesto que si usaron micro-F1, nuestro modelo lo superaría por mucho más.

como el clínico, en el que ya se encuentran disponibles algunos corpus marcados con indicadores de negación y sus alcances [8].

Agradecimientos. Este trabajo fue posible gracias al CONACyT, entidad que otorga las becas doctorales a dos de los autores de este trabajo.

Referencias

1. Martí, M. A., Taulé, M., Nofre, M., Marsó, L., Martín-Valdivia, M. T., Jiménez-Zafra, S. M.: La negación en español: análisis y tipología de patrones de negación. *Procesamiento del Lenguaje Natural* (57), 41–48 (2016)
2. Savova, G. K., Masanz, J. J., Ogren, P. V., Zheng, J., Sohn, S., Kipper-Schuler, K. C., Chute, C. G.: Mayo clinical Text Analysis and Knowledge Extraction System (cTAKES): architecture, component evaluation and applications. *Journal of the American Medical Informatics Association*, 17(5), 507–513 (2010)
3. Baker, K., Bloodgood, M., Dorr, B. J., Callison-Burch, C., Filardo, N. W., Piatko, C., ... Miller, S.: Modality and negation in simt use of modality and negation in semantically-informed syntactic mt. *Computational Linguistics*, 38(2), 411–438 (2012)
4. Cruz, N. P., Taboada, M., Mitkov, R.: A machine-learning approach to negation and speculation detection for sentiment analysis. *Journal of the Association for Information Science and Technology*, 67(9), 2118–2136 (2016)
5. Reitan, J., Faret, J., Gambäck, B., Bungum, L.: Negation scope detection for twitter sentiment analysis. In: *Proceedings of the 6th Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis*, pp. 99–108 (2015)
6. Tamayo, A., Londoño, J. A., Burgos, D., Quiroz, G.: Sentiment Analysis of News Articles in Spanish using Predicate Features. *Lenguaje*, 47(2), 235–267 (2019)
7. Díaz, N. P. C., López, M. J. M.: Negation and speculation detection, Vol. 13, John Benjamins Publishing Company (2019)
8. Cotik, V., Stricker, V., Vivaldi, J., Rodríguez Hontoria, H.: Syntactic methods for negation detection in radiology reports in Spanish. In: *Proceedings of the 15th Workshop on Biomedical Natural Language Processing, BioNLP 2016: Berlin, Germany, August 12, 2016*, pp. 156–165, Association for Computational Linguistics (2016)
9. Wendy W. Chapman, Will Bridewell, Paul Hanbury, Gregory F. Cooper, and Bruce G. Buchanan. 2001a. A Simple Algorithm for Identifying Negated Find- ings and Diseases in Discharge Summaries. *Journal of Biomedical Informatics*, 34(5): 301–310 (2001)
10. Jiménez-Zafra, S. M., Taulé, M., Martín-Valdivia, M. T., Ureña-López, L. A., Martí, M. A.: SFU Review SP-NEG: a Spanish corpus annotated with negation for sentiment analysis. A typology of negation patterns. *Language Resources and Evaluation*, 52(2), 533–569 (2018)
11. Gindl, S., Kaiser, K., Miksch, S.: Syntactical negation detection in clinical practice guidelines. *Studies in health technology and informatics*, 136, 187 (2008)
12. Harkema, H., Dowling, J. N., Thornblade, T., Chapman, W. W.: ConText: an algorithm for determining negation, experienter, and temporal status from clinical reports. *Journal of biomedical informatics*, 42(5), 839–851 (2009)

13. Apostolova, E., Tomuro, N., Demner-Fushman, D.: Automatic extraction of lexico-syntactic patterns for detection of negation and speculation scopes. In: Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies: short papers-Volume 2, pp. 283–287, Association for Computational Linguistics (2011)
14. Vincze, V., Szarvas, G., Farkas, R., Móra, G., Csirik, J.: The BioScope corpus: biomedical texts annotated for uncertainty, negation and their scopes. *BMC bioinformatics*, 9(11), 1–9 (2008)
15. Rokach, L., Romano, R., Maimon, O.: Negation recognition in medical narrative reports. *Information Retrieval*, 11(6), 499–538 (2008)
16. Morante, R., Liekens, A., Daelemans, W.: Learning the scope of negation in biomedical texts. In: Proceedings of the 2008 conference on empirical methods in natural language processing, pp. 715–724 (2008)
17. Morante, R., Daelemans, W.: A metalearning approach to processing the scope of negation. In: Proceedings of the thirteenth conference on computational natural language learning (CoNLL-2009), pp. 21–29 (2009)
18. Cruz Díaz, N. P., Mana López, M. J., Vázquez, J. M., Álvarez, V. P.: A machine-learning approach to negation and speculation detection in clinical texts. *Journal of the American society for information science and technology*, 63(7), 1398–1410 (2012)
19. Wu, S., Miller, T., Masanz, J., Coarr, M., Halgrim, S., Carrell, D., Clark, C.: Negation's not solved: Generalizability versus optimizability in clinical natural language processing. *PloS one*, 9(11) (2014)
20. Councill, I. G., McDonald, R., Velikovich, L.: What's great and what's not: Learning to classify the scope of negation for improved sentiment analysis. In: Proceedings of the workshop on negation and speculation in natural language processing, pp. 51–59, Association for Computational Linguistics (2010)
21. Agarwal, S., Yu, H.: Biomedical negation scope detection with conditional random field. *Journal of the American medical informatics association*, 17(6), 696–701 (2010)
22. Zhu, Q., Li, J., Wang, H., Zhou, G.: A unified framework for scope learning via simplified shallow semantic parsing. In: Proceedings of the 2010 Conference on Empirical Methods in Natural Language Processing, pp. 714–724, Association for Computational Linguistics (2010)
23. Zou, B., Zhou, G., Zhu, Q.: Tree kernel-based negation and speculation scope detection with structured syntactic parse features. In: Proceedings of the 2013 conference on empirical methods in natural language processing, pp. 968–976 (2013)
24. Shivade, C., de Marneffe, M. C., Fosler-Lussier, E., Lai, A. M.: Extending NegEx with kernel methods for negation detection in clinical text. In: Proceedings of the Second Workshop on Extra-Propositional Aspects of Meaning in Computational Semantics (ExProM 2015), pp. 41–46 (2015)
25. Attardi, G., Cozza, V., Sartiano, D.: Detecting the scope of negations in clinical notes. *CLiC it*, 14 (2015)
26. Goryachev, S., Sordo, M., Zeng, Q. T., Ngo, L.: Implementation and evaluation of four different methods of negation detection, pp. 2826–2831, Technical report, DSG (2006)
27. Huang, Y., Lowe, H. J.: A novel hybrid approach to automated negation detection in clinical radiology reports. *Journal of the American medical informatics association*, 14(3), 304–311 (2007)

28. Fujikawa, K., Seki, K., Uehara, K.: NegFinder: A web service for identifying negation signals and their scopes. *Information and Media Technologies*, 8(3), 884–889 (2013)
29. White, J. P.: UWashington: Negation resolution using machine learning methods. In: *Proceedings of the First Joint Conference on Lexical and Computational Semantics-Volume 1: Proceedings of the main conference and the shared task, and Volume 2: Proceedings of the Sixth International Workshop on Semantic Evaluation*, pp. 335–339, Association for Computational Linguistics (2012)
30. Gyawali, B., Solorio, T.: UABCoRAL: a preliminary study for resolving the scope of negation. In: *Proceedings of the First Joint Conference on Lexical and Computational Semantics-Volume 1: Proceedings of the main conference and the shared task, and Volume 2: Proceedings of the Sixth International Workshop on Semantic Evaluation*, pp. 275–281, Association for Computational Linguistics (2012)
31. Pröllochs, N., Feuerriegel, S., Neumann, D.: Understanding Negations in Information Processing: Learning from Replicating Human Behavior. Available at SSRN 2954460 (2017)
32. Fancellu, F., Lopez, A., Webber, B.: Neural networks for negation scope detection. In: *Proceedings of the 54th annual meeting of the Association for Computational Linguistics (volume 1: long papers)*, pp. 495–504 (2016)
33. Qian, Z., Li, P., Zhu, Q., Zhou, G., Luo, Z., Luo, W.: Speculation and negation scope detection via convolutional neural networks. In: *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*, pp. 815–825 (2016)
34. Lazib, L., Zhao, Y., Qin, B., Liu, T.: Negation scope detection with recurrent neural networks models in review texts. *International Journal of High Performance Computing and Networking*, 13(2), 211–221 (2016)
35. Fei, H., Ren, Y., Ji, D.: Negation and speculation scope detection using recursive neural conditional random fields. *Neurocomputing*, 374, 22–29 (2020)
36. Fabregat, H., Araujo Serna, L., Martínez Romo, J.: Deep learning approach for negation trigger and scope recognition. *Procesamiento de Lenguaje Natural*, 62, 37–44 (2019)
37. Jiménez-Zafra, S. M., Díaz, N. P. C., Morante, R., Martín-Valdivia, M. T.: Neges 2018: Workshop on negation in spanish. *Procesamiento del Lenguaje Natural*, 62, 21–28 (2019)
38. Jiménez-Zafra, S. M., Cruz Díaz, N. P., Morante, R., Martín-Valdivia, M. T.: NEGES 2019 Task: Negation in Spanish. In: *Proceedings of the Iberian Languages Evaluation Forum (IberLEF 2019)*. CEUR Workshop Proceedings, CEUR-WS, Bilbao, Spain (2019)
39. Ramshaw, L. A., Marcus, M. P.: Text chunking using transformation-based learning. In: *Natural language processing using very large corpora*, pp. 157–176, Springer, Dordrecht (1999)
40. Lafferty, J., McCallum, A., Pereira, F. C.: Conditional random fields: Probabilistic models for segmenting and labeling sequence data. In: *Proceedings of the 18th International Conference on Machine Learning 2001 (ICML 2001)*, pp. 282–289 (2001)