

Análisis de Sentimientos Aplicado a Referencias Bibliográficas

Hernández M.*; Gómez J.**

**Escuela Politécnica Nacional, Facultad de Ingeniería de Sistemas

e-mail: myriam.hernandez@epn.edu.ec

** Universidad de Alicante, Departamento de Lenguajes y Sistemas Informáticos

e-mail: jmgomez@ua.es

Resumen: Actualmente índices como el hindex calculan el impacto de un artículo científico considerando solamente el número y la frecuencia con que una cita bibliográfica es mencionada, sin tomar en cuenta el propósito ni la polaridad con que fue referenciada; éste método de cómputo puede llevar a conclusiones equivocadas a la hora de valorar la contribución científica de algunos investigadores o el impacto de las revistas en las que publican. En este trabajo se propone complementar las medidas cuantitativas de impacto con criterios subjetivos usando Análisis de Sentimientos para detectarlos en el contexto de citas bibliográficas dentro del texto de los artículos. Se presenta una visión general de lo que involucra el Análisis de Sentimientos basado en los enfoques de reconocimiento de patrones y aprendizaje automático; se plantea una propuesta de diseño que combine estas técnicas, las aplique en referencias bibliográficas y obtenga nuevos elementos para una visión más completa de la influencia de un artículo en la literatura científica.

Palabras clave: Análisis de sentimientos, bibliometría, polaridad, reglas, aprendizaje automático.

Abstract: Currently indexes like hindex, calculate the impact of a scientific article considering only the number and the frequency of citation mentions, regardless of the purpose or polarity that authors intended; this method of calculation may be misleading when evaluating the scientific contribution of some researchers or the impact of the journals in which they publish. This paper aims to complement quantitative measures of impact analysis using subjective criteria detected with Sentiment Analysis in the context of citations in the text of the articles. We present an overview of what is involved in Sentiment Analysis using different approaches: pattern recognition and machine learning based technologies; we present a design proposal that combines these techniques applied in the context of bibliographic references to obtain a more complete view of the influence of an article in the scientific literature.

Keywords: Sentiment analysis, bibliometrics, polarity, rules, machine learning.

1. INTRODUCCION

Una cita bibliográfica es un texto que aparece en un artículo científico y referencia un trabajo previo con distintos propósitos como, por ejemplo, para comparar resultados o reconocer las fuentes usadas. Las citas en un texto científico normalmente son numerosas. Conectan piezas de trabajos de investigación a través de distintos periodos de tiempo y diferentes comunidades en la literatura científica. La clasificación subjetiva de estas referencias proporciona información valiosa que facilita la investigación. Este tipo de citas categorizadas se aplican para generar resúmenes y revisiones automáticas.

Los índices de impacto como el hindex [7] se relacionan con el número de veces que un artículo ha sido citado. En el cálculo de este tipo de índices, una cita se interpreta como que un autor A ha sido influenciado por el trabajo de un autor B, sin especificar el tipo de influencia [11]. Tratar a todas las referencias de igual manera puede llevar a conclusiones equivocadas en cuanto al verdadero impacto de una cita

bibliográfica [14]. Por ello, se considera necesario analizar otros indicadores que muestren la intención del autor al realizar la referencia. El análisis automático de criterios subjetivos presentes en un texto se conoce como Análisis de Sentimientos (AS) y podría servir para complementar la estimación del impacto de una publicación.

El AS, es un tema actual de investigación en el área de procesamiento del lenguaje natural en el campo de extracción de la información; su campo de aplicación es muy amplio en el monitoreo de emociones en disciplinas tan diversas como el marketing, ciencias políticas y economía.

El AS se puede aplicar en el estudio de citas bibliográficas, usando el contexto de las citas para detectar la intención y sentimientos de un autor al hacer una referencia o cita bibliográfica dentro de un artículo científico. Con esta información se puede mejorar el análisis bibliométrico de las referencias [1]. El análisis sintáctico y semántico del contenido de las oraciones alrededor de las citas se obtiene de las teorías existentes sobre ellas como se presenta en la Tabla 1 que ha sido adaptada a partir de [11].

Para realizar avances en el análisis de las citas es necesario que se combinen las dos orientaciones principales que se

manejan en estos momentos: descripción cuantitativa de las referencias bibliográficas y la descripción cualitativa de las mismas [11].

La cámara tiene excelentes lentes, pero el precio es muy alto. Yo no creo que la calidad del cargador presente problemas. (1)

Tabla 1: Bases teóricas para entender las principales características de una cita bibliográfica

Características y Orientación	Origen conceptual	Lo que asume	Métodos analíticos
N Numérica - Explícita	La ciencia necesita medir los distintos fenómenos	El número de citas puede ser considerado o un indicador de impacto	Conteo de citas, frecuencia de citas
L Literal - Explícita / Implícita	La naturaleza simbólica de las palabras	Las palabras y elecciones lingüísticas en el texto en que se realizan las citas pueden indicar la función y sentimiento o de la cita	Procesamiento de lenguaje natural, aprendizaje automático
S Socio cultural - Implícita	La naturaleza individual y social de las selecciones	El contenido semántico del contexto de las citas sugiere las motivaciones de las citas	Análisis de contenido

- [favorable] excelentes (lentes) (1a)
- [no favorable] alto (precio) (1b)
- [favorable] problemático^{+neg} (cargador) (1c)

La extracción de estas unidades de sentimientos se llama traducción de texto a unidades de sentimiento. Esta no es una tarea trivial porque se requieren muchas operaciones de tipo sintáctico y semántico, que incluyen extracción de los argumentos de la oración, manejo de información expresada como negación, desambiguación de sentimientos para detectar que “alto” en este caso es negativo al aplicarse a precio, a pesar de que podría ser un adjetivo positivo si se aplicara a otro parámetro, como por ejemplo, calidad. En esta tarea se pueden reusar herramientas de traducción automática [8].

El AS tiene como objetivo 3 tareas esenciales, de acuerdo a [4]: la extracción de la polaridad objetivo/subjetiva del texto (polaridad SN) [18], la determinación de la polaridad positivo / negativa (polaridad PN) del texto y la intensidad de la polaridad PN. Recursos léxicos de acceso libre como SentiWordNet [4] aplican este análisis y tienen unidades asociadas a tres valores numéricos, cada uno de los cuales describen cuán objetivos, positivos y negativos, respectivamente, son los términos contenidos en ellas.

El AS enfrenta problemas debido a la naturaleza misma del lenguaje humano, cuya estructura presenta dificultades para la detección automática. Para lograr una mayor precisión en la determinación de la polaridad, se sugiere aplicar una combinación de técnicas que permitan mejorar los resultados. En este contexto, una técnica adicional que se puede aplicar es el análisis de discurso.

En [21] se muestra que métodos híbridos de clasificación que combinan distintos algoritmos y enfoques, pueden mejorar la eficiencia de este análisis en términos de micro y macro F1 promedio. Siendo F1 una medida que toma la precisión y la recuperación como medidas de la eficiencia del clasificador. Otra forma de mejorar la eficiencia es el uso consecutivo de clasificadores de distinto tipo para lograr una sinergia en su funcionamiento y una mejor eficiencia.

La Tabla 2 (adaptada de [21]), muestra la forma como se obtendrían estas métricas para determinar la eficiencia de los algoritmos en AS, la tabla se refiere a la comparación entre los sentimientos evaluados por un humano versus los clasificados por una máquina.

Hay que tomar en cuenta la dificultad que presenta comparar objetivamente la eficiencia de distintos enfoques para AS debido a la aplicación de diversos métodos de evaluación y de datos de prueba.

2. ANÁLISIS DE SENTIMIENTOS

2.1 Visión general

El AS se refiere en general a la extracción de entidades que indican emociones en un texto para clasificarlas como positivas, negativas o neutras. Hay distintos enfoques para el análisis de sentimientos que a la final termina siendo una categorización de palabras que se puede realizar con técnicas basadas en reconocimientos de patrones, o usando aprendizaje automático ya sea supervisado, no supervisado o híbrido [13].

La extracción de unidades que expresan sentimientos en un texto se puede hacer usando distintos métodos como el planteado por [6], donde una unidad de sentimiento está conformada por un sentimiento, un predicado y su argumento. Por ejemplo, las siguientes oraciones en un comentario de un cliente de una cámara digital, contiene tres unidades de sentimientos (1a), (1b) y (1c). Aparentemente estas unidades indican que la cámara tiene buenas características en sus lentes y cargador y una mala característica en su precio.

Tabla 2: Aciertos

	La máquina dice SI	La máquina dice NO
El humano dice SI	True positive = TP	Fail negative= FN
El humano dice NO	Fail positive = FP	True negative = TN

Con estos valores se pueden calcular las variables precisión, recuperación y F1 para medir la eficiencia de los algoritmos para AS.

$$\begin{aligned} \text{Precisión (P)} &= TP / (TP + FP) \\ \text{Recuperación (R)} &= TP / (TP + FN) \\ \text{F1} &= 2 \cdot P \cdot R / (P + R) \end{aligned} \quad (2)$$

2.2 Técnicas

Se puede entender al AS como una categorización de palabras de acuerdo a características predefinidas que son palabras o conjuntos de palabras que denotan sentimientos positivos, negativos o neutrales.

En trabajos existentes, para automatizar el análisis de sentimientos se han aplicado diferentes enfoques, algunos relacionados con procesamiento de lenguaje natural (PLN) y basados en reconocimiento de patrones [8], otros usan algoritmos de aprendizaje automático y también aprendizaje no supervisado.

Los enfoques basados en PLN y reconocimiento de patrones se enfocan en el uso de herramientas de procesamiento como etiquetadores de las distintas partes de las oraciones y sentencias (etiquetadores de Part-of-Speech POS) y analizadores sintácticos. Las etiquetas PoS permiten clasificar el componente como adverbio, verbo, adjetivo, sustantivo, etc. como parte del análisis sintáctico; lo que permite pasar a la siguiente etapa o análisis semántico y posteriormente a la extracción de unidades de sentimientos. Los resultados generados por las herramientas se procesan para generar una colección de patrones. Cada patrón tiene asignado un sentimiento positivo o negativo y por lo tanto tienen definida su polaridad. Este tipo de tareas las realiza, por ejemplo, el analizador sintáctico Montylingua [10].

Las características pueden ser ngramas, donde n corresponde al número de palabras que componen la frase que va a ser analizada. Por ejemplo “excelente” es un unigrama, “terriblemente complicado” es un bigrama, “un gran trabajo” es un trigramas. Los unigramas normalmente no son suficientemente específicos y no se usan para extracción de unidades de sentimiento, los bigramas son los más utilizados y los trigramas son muy específicos lo que les hace perder frases que pueden ser importantes. Normalmente no se usan combinaciones de más de tres palabras, pero podrían ser de utilidad si es que estamos en una búsqueda definida, por ejemplo de un título de un artículo que se está analizando. Este tipo de búsqueda es computacionalmente simple y fácil de entender pero puede requerir de una larga lista de

palabras. Las palabras de los ngramas se ubican en una colección conocida como “Bag-of-Words”.

El aprendizaje no supervisado se enfoca en explotar corpus de prueba para determinar el sentimiento de una expresión, se puede inferir la polaridad de las palabras con su asociación estadística usando un conjunto de palabras paradigma que sirva como ejemplo para mostrar sus distintas posibles acepciones tanto positivas como negativas como se presenta en [20].

En el aprendizaje automático algoritmos muy utilizados son Naïve Bayes y Support Vector Machine, entre otros [15].

Los métodos híbridos combinan distintos tipos de clasificadores en distinto orden y secuencia hasta lograr una mejora de la eficiencia. Este resultado puede variar de acuerdo a los campos de aplicación y se requeriría experimentación para determinar la mejor combinación y secuencia [21]. Por último, existen sistemas que utilizan recursos externos como léxicos especializados en AS, por ejemplo, SentiWordNet, para introducir esta información como características a los modelos de entrenamiento [5]. De esta forma no sólo se enriquece el modelo con información léxica y sintáctica, sino que se incluye también información semántica.

3. CLASIFICADORES BASADOS EN RECONOCIMIENTO DE PATRONES VS CLASIFICADORES CON APRENDIZAJE AUTOMÁTICO

Los clasificadores basados en reconocimiento de patrones son diferentes a los que usan aprendizaje automático porque parten de un mecanismo subyacente distinto. Se definen un grupo de reglas que se extraen de corpus de prueba como un grupo de patrones, para ello se usan plantillas o métodos heurísticos. De acuerdo a [21], el mapeo entre cada patrón y una categoría lleva a la construcción y la optimización de un conjunto de reglas.

Una regla consiste de un antecedente y un consecuente. Un antecedente se define como una condición que consiste de un token o secuencia de tokens concatenados por el operador ^. Un token puede ser una palabra “?” o un término objetivo “#” que varía de acuerdo al contexto del análisis, puede ser por ejemplo el nombre de un autor de un artículo. El consecuente representa un sentimiento positivo o negativo.

$$\begin{aligned} \{ [\text{token 1}] \wedge [\text{token 2}] \wedge \dots \wedge [\text{token n}] \} &\rightarrow \{ + / - \} \\ \{ \text{excelente} \} &\rightarrow \{ + \} \\ \{ \text{absurdo} \} &\rightarrow \{ - \} \end{aligned} \quad (3)$$

Se asumen dos sentencias:

1. Laptop-A es más costoso que Laptop-B
2. Laptop-A es más costoso que Laptop-C

La palabra objetivo es Laptop-A. La regla derivada de estas sentencias es:

$$\{ \# \wedge \text{ más } \wedge \text{ costoso } \wedge \text{ que } \wedge ? \} \rightarrow \{-\} \quad (5)$$

La interpretación de esta regla es que Laptop-A tiene un sentimiento más negativo que las otras dos debido a su precio.

Para la extracción de reglas se toma en cuenta también la presencia de negación o la proximidad de otras oraciones. Dado un conjunto de entrenamiento el patrón asociado se enfoca en extender la regla existente o manejar un nuevo conjunto de ejemplo u optimizar las reglas existentes para habilitar una concordancia eficiente (inducción de reglas).

En contraste un clasificador con aprendizaje automático considera un conjunto de características significativas, cada una de las cuales tiene asignado un peso. Por lo tanto, dado un conjunto de entrenamiento, el modelo asociado se enfoca en optimizar los pesos y otros parámetros de tal manera que el modelo puede lograr un alto nivel de eficiencia en un conjunto de ejemplo no visto anteriormente. Se asume la independencia de características lo que no es siempre cierto. Adicionalmente, se tiene que hacer a veces un compromiso entre la eficiencia del modelo y el tiempo que se necesita para entrenarlo. Un algoritmo de aprendizaje automático eficiente se requiere para entrenar el modelo. Posteriormente, un clasificador hará uso del modelo que contiene los pesos aprendidos y los parámetros para clasificar un ejemplo no visto.

3.1 Técnicas de clasificación usando aprendizaje automático

Debido a que son ampliamente usados en el aprendizaje automático para determinar la categoría de los sentimientos en un texto, en el presente trabajo se van a mencionar dos algoritmos: Naïve Bayes [15], y Support Vector Machines (SVM) [12].

3.2 Naïve Bayes

Aplica un marco probabilístico y usa el teorema de Bayes para calcular la probabilidad de una clase (positiva, negativa). Por ejemplo, dado un texto X cuya clase no se conoce, y una clase particular C, la probabilidad de una clase C de un texto se calcula con el Teorema de Bayes:

$$P(C|X) = P(X|C)P(C)/P(X) \quad (6)$$

Donde $P(C|X)$ es la probabilidad a posteriori una clase C basada en el texto X. $P(X|C)$ es la probabilidad posterior de un texto dada una clase. $P(C)$ es la probabilidad de una clase. $P(X)$ es la probabilidad de un texto. Se asume que las probabilidades de las características son independientes de la clase.

3.3 Support Vector Machine

El algoritmo SVM explota el uso de vectores que modelan la distribución de características en un texto.

Como se presenta en la Fig. 1, cada vector es un punto de un espacio n-dimensional, donde n es el número de características que contienen un valor booleano que indica si la característica existe en el texto o un número que representa la frecuencia de ocurrencia de la característica. El objetivo de SVM es modelar un hiperplano que divide grupos de vectores en categorías separadas maximizando la separación entre los datos de entrenamiento. En su forma más simple SVM diferencia entre dos categorías. Los vectores soporte son los más cercanos a la línea. La tarea es determinar los vectores que mejor describen la división entre categorías que tengan la mayor distancia entre clases (margen).

En el caso de datos que no son linealmente separables Fig. 2 se utilizan Kernels que mapean un espacio a otro con más dimensiones en el cual el espacio de características es separable para el set de entrenamiento Fig. 3.

Por ejemplo:

Un texto (cadena) se representa como el conteo de todas las subcadenas de k caracteres.

$$\Theta = (T) = (\# \text{subcadenastipo}_1, \dots, \# \text{subcadenastipo}_n) \quad (7)$$

La función tiene n dimensiones.

Función Kernel: Conteo de todas las subcadenas que coinciden.

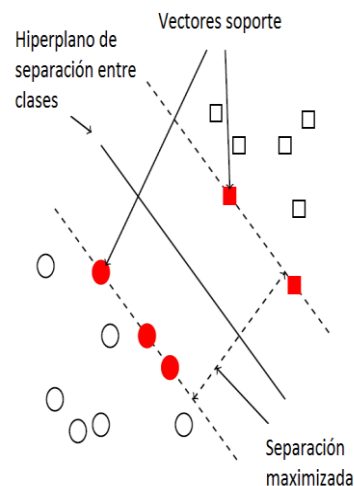


Figura 1: Algoritmo SVM




Figura 2: clases no linealmente separables en un espacio de dos dimensiones




Figura 3: Clases linealmente separables en un espacio de tres dimensiones

En un enfoque de Bag-of-Words en un Kernel de cadena se tienen subcadenas separadas con espacios en blanco:

$\vec{b} = (\#Yo, \#estoy, \#realmente, \#muy, \#feliz, \#infeliz, \#con, \#esta, \#cámara)$

$x =$ Yo estoy realmente feliz con esta cámara.

$\vec{x} = (1,1,1,0,1,0,1,1,1)$ (8)

$z =$ Yo estoy muy infeliz con esta cámara.

$\vec{z} = (1,1,0,1,0,1,1,1,1)$

La comparación se hace fácilmente en el Kernel y no con el espacio inicial. Este método no requiere que conozcamos el separador de las clases en el espacio inicial.

$$K(\vec{x}, \vec{z}) = \sum (x_i \cdot z_i) = 4 \quad (9)$$

K nos da el valor del margen de separación entre las clases. Muchas aplicaciones usan árboles para análisis sintáctico. En este caso también se puede usar SVM cambiando el árbol a un vector de características enumerando todas las ramas de dos nodos y siguiendo un procedimiento similar al descrito, contando el número de ramas comunes.

Se pueden poblar los vectores de características para el SVM usando recursos léxicos y semánticos como WordNet [20], SentiWordNet [4] o WordNetAffect [17]. También se pueden utilizar herramientas de análisis de textos para obtener información léxica o sintáctica como el Freeling [3], Stanford NLP [16] o MiniPAR [9]. El WordNet es una base de datos léxica en inglés aunque tiene sus correspondientes versiones en otros idiomas como el EuroWordNet [19]. Los sustantivos, verbos, adjetivos y adverbios se agrupan en colecciones de sinónimos cognitivos (synsets), cada uno de los cuales expresa un concepto distinto. Los synsets se interrelacionan léxicamente y semánticamente. Los recursos como el SentiWordNet y el WordNetAffect relacionan algunos de los synset de WordNet que normalmente expresan sentimientos con su polaridad e intensidad. Diversas combinaciones de todos estos recursos han sido utilizadas en sistemas de aprendizaje automático con SVM [5], [2].

3.4 Análisis de Contexto

Según [11] y [12] se asume que las palabras alrededor de la cita objetivo proporcionan evidencia semántica para inferir la motivación del autor que la referencia. Si la cita contribuye al tema central, en el análisis bibliométrico se debería acreditar un mayor valor a su impacto. La ubicación de la entrada bibliográfica dentro del artículo científico proporciona información sobre la función de la cita. En [6] se establece que citas múltiples a una referencia indica una relación cercana y útil de esa referencia al artículo que la menciona. Una publicación citada en la introducción o en la sección de revisión de la literatura y mencionada nuevamente en la metodología o en la sección de discusión, ofrece una mayor contribución a la publicación que otras que han sido mencionadas una sola vez.

Por otro lado, la ventana que rodea a la cita objetivo $\{-n$ palabras, $+n$ palabras $\}$ se usa para inferir el sentimiento y propósito del autor al hacer la referencia. [11] sugiere un n de 150, pero aclara que deben realizarse pruebas para hallar un valor óptimo para el tamaño de la ventana.

4. PLANTEAMIENTO DE UN SISTEMA PARA ANÁLISIS DE SENTIMIENTOS APLICADO A REFERENCIAS BIBLIOGRÁFICAS

Se plantea desarrollar un sistema analizador de polaridad de sentimientos de referencias bibliográficas en artículos científicos, soportado por métodos híbridos que combinen varios enfoques y tecnologías con el fin de producir resultados confiables por su mayor eficiencia en cuanto a recuperación y precisión; los resultados se compararán con una línea base del estado del arte actual. Se tiene la visión de realizar un análisis fundamentado en el contexto próximo de las citas. El sistema tendrá las características generales que se describen en el diagrama lógico y los módulos propuestos, que se refieren a continuación.

4.1 Diagrama Lógico

El diagrama lógico se presenta en la Fig. 4. La arquitectura se define por capas para permitir reutilización, estandarización, flexibilidad y facilidad en el manejo de errores.

La capa de interfaz permite la comunicación con sistemas externos y cómo se presenta los resultados al usuario. La capa de aplicación maneja la lógica de los algoritmos y tecnologías para el rastreador, extractor y analizador de sentimientos. La capa de negocio gestiona la comunicación y el flujo de trabajo entre la interfaz web y las aplicaciones. La capa de persistencia maneja el almacenamiento de las entradas y salidas del sistema.

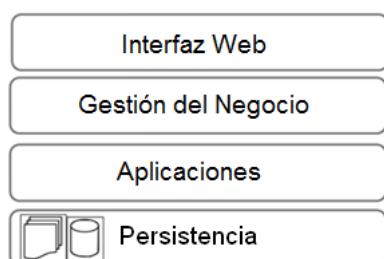


Figura 4: Arquitectura

4.2 Módulos principales

El sistema que se plantea desarrollar, se muestra en la Fig. 5 con los siguientes módulos principales:

- **Interfaz web:** Gestiona las entradas y salidas del sistema y proporciona un método de comunicación entre el usuario final y el sistema.
- **Rastreador de referencias bibliográficas:** Navega artículos científicos y obtiene las referencias bibliográficas.
- **Extracción de información:** Sistema que, a partir de una referencia bibliográfica obtenida por el rastreador, es capaz de extraer cada uno de sus campos (título, autores, revista, año publicación, editor, etc.) junto con información de contexto en la referencia. Obtiene la información objetivo dentro de una ventana con un tamaño escogido heurísticamente con el fin de agregar contexto suficiente y se calculan indicadores de ubicación y frecuencia de las entradas objetivo.
- **Analizador de textos:** Dividen las oraciones contenidas en las ventanas alrededor de las citas en sus partes sintácticas: verbos, sustantivos, adjetivos, adverbios, etc. (POS Tagging).
- **Analizador de sentimientos:** Definen unidades de sentimientos. Aplica en los datos obtenidos combinaciones de las tecnologías mencionadas en este artículo y otras que sean adecuadas hasta lograr resultados aceptables en la determinación del sentimiento de los ngramas para los autores

definidos dentro de las palabras objetivos. Además trabajan en el establecimiento del propósito del autor al realizar la referencia.

- **Repositorio:** Almacena información de entrada y salida del sistema.

5. CONCLUSIONES

En este trabajo se ha planteado el desarrollo de un sistema de análisis de polaridad de sentimientos aplicado a referencias bibliográficas. Se propone usar una combinación de enfoques y tecnologías que permita una sinergia entre ellos hacia el logro de resultados confiables.

La tarea básica del AS es la definición de polaridad de sentimientos, lo que en el análisis de citas bibliográficas dentro de un artículo técnico está relacionado con la determinación de si la entrada fue referenciada en forma positiva o negativa. De la polaridad puede inferirse el tipo de impacto, función y contribución de la cita en ese artículo.

Debido a la naturaleza del lenguaje natural, existen retos que aún no han sido resueltos en la detección automática de la polaridad en un texto. Aún se requiere un mejor entendimiento del puente que existe entre las estructuras sintácticas y semánticas del lenguaje natural y la información estructurada, procesable por una computadora, que pueda analizar las oraciones cercanas a la entrada bibliográfica y obtener elementos subjetivos que aporten a la determinación de su verdadera influencia.

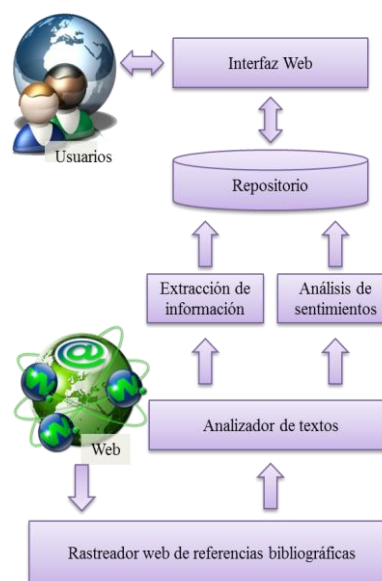


Figura 5: Módulos del sistema

REFERENCIAS

- [1] A. Abu-Jbara and D. R. Radev, (2012, June). Reference scope identification in citing sentences. In *Proceedings of the 2012 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies* (pp. 80-90). Association for Computational Linguistics.
- [2] E. Boldrini, J. Fernández, J.M. Gómez and P. Martínez Barco. (2011). EmotiBlog: towards a finer-grained sentiment analysis and its application to opinion mining. *Actas de las IV Jornadas TIMM*.
- [3] X. Carreras, I. Chao, L. Padró and M. Padró. FreeLing: An Open-Source Suite of Language Analyzers Proceedings of the 4th International Conference on Language Resources and Evaluation (LREC'04), 2004.
- [4] A. Esuli and F. Sebastiani (2006). SentiWordNet: A Publicly Available Lexical Resource for Opinion Mining. *Proceedings of LREC 2006 – 5th Conference on Language Resources and Evaluation, 22-28/5/2006, Genova (IT)*.
- [5] J. Fernández, E. Boldrini, J. M. Gómez, and P. Martínez-Barco, (2011). Evaluating EmotiBlog robustness for sentiment analysis tasks. In *Natural Language Processing and Information Systems* (pp. 290-294). Springer Berlin Heidelberg.
- [6] G. Herlach, (1978). Can retrieval of information from citation indexes be simplified? Multiple mention of a reference as a characteristic of the link between cited and citing article. *Journal of the American Society for Information Science*, 29(6), 308-310.
- [7] J. E. Hirsch, (15 November 2005). An index to quantify an individual's scientific research output. *PNAS* 102 (46): 16569–16572.
- [8] K. Hiroshi, N. Tetsuya and W. Hideo, (2004, August). Deeper sentiment analysis using machine translation technology. In *Proceedings of the 20th international conference on Computational Linguistics* (p. 494). Association for Computational Linguistics.
- [9] D. Lin (2003). Dependency-based evaluation of MINIPAR. In *Treebanks* (pp. 317-329). Springer Netherlands.
- [10] H. Liu, (2004). MontyLingua: An end-to-end natural language processor with common sense. Available at <http://web.media.mit.edu/hugo/montylingua>
- [11] X. Liu, J. Zhang and C. Guo, (2012, October). Full-text citation analysis: enhancing bibliometric and scientific publication ranking. In *Proceedings of the 21st ACM international conference on Information and knowledge management* (pp. 1975-1979). ACM.
- [12] M. D. Lytras, and P. Ordonez de Pablos, (2009). *Social Web Evolution: Integrating Semantic Applications and Web 2.0 Technologies*. Information Science Reference-Imprint of: IGI Publishing.
- [13] R. Prabowo, and M. Thelwall, (2009). Sentiment analysis: A combined approach. *Journal of Informetrics*, 3(2), 143-157.
- [14] F. Radicchi, (2012). In science “there is no bad publicity”: Papers criticized in comments have high scientific impact. *Scientific reports*, 2.
- [15] F. Sebastiani (2002). Machine Learning in Automated Text Categorization. *ACM Computing Surveys*, 34(1), 1-47.
- [16] Stanford NLP. <http://nlp.stanford.edu/software/index.html>. Verificado por última vez: 04 October, 2013.
- [17] C. Strapparava and A. Valitutti, (2004). WordNet Affect: an Affective Extension of WordNet. In *LREC (Vol. 4, pp. 1083-1086)*.
- [18] P. D. Turney, and M. L. Littman, (2003). Measuring praise and criticism: Inference of semantic orientation from association. *ACM Transactions on Information Systems (TOIS)*, 21(4), 315-346.
- [19] P. Vossen, (1998). EuroWordNet: a multilingual database with lexical semantic networks. Boston: Kluwer Academic.
- [20] WordNet. <http://wordnet.princeton.edu/>. Verificado por última vez: 02 October, 2013.
- [21] G. Zhang, Y. Ding and S. Milojević, (2013). Citation content analysis (cca): A framework for syntactic and semantic analysis of citation content. *Journal of the American Society for Information Science and Technology*.