

# La web semántica

Pablo Castells  
Escuela Politécnica Superior  
Universidad Autónoma de Madrid  
pablo.castells@uam.es  
<http://www.ii.uam.es/~castells>

## Resumen

La web semántica es un área pujante en la confluencia de la Inteligencia Artificial y las tecnologías web que propone introducir descripciones explícitas sobre el significado de los recursos, para permitir que las propias máquinas tengan un nivel de comprensión de la web suficiente como para hacerse cargo de una parte, la más costosa, rutinaria, o físicamente inabarcable, del trabajo que actualmente realizan manualmente los usuarios que navegan e interactúan con la web. A partir de la situación actual de la web y sus limitaciones, en este artículo se motivan y explican las propuestas de la web semántica, se describen las tecnologías más importantes desarrolladas para llevarlas a cabo, así como el punto en el que se encuentra este proyecto promovido por el propio inventor de la web.

## Introducción

En poco más de una década desde su aparición, la *World Wide Web* se ha convertido en un instrumento de uso cotidiano en nuestra sociedad, comparable a otros medios tan importantes como la radio, la televisión o el teléfono, a los que aventaja en muchos aspectos. La web es hoy un medio extraordinariamente flexible y económico para la comunicación, el comercio y los negocios, ocio y entretenimiento, acceso a información y servicios, difusión de cultura, etc. Paralelamente al crecimiento espectacular de la web, las tecnologías que la hacen posible han experimentado una rápida evolución. Desde las primeras tecnologías básicas: HTML<sup>1</sup> y HTTP<sup>2</sup>, hasta nuestros días, han emergido tecnologías como CGI,<sup>3</sup> Java,<sup>4</sup> JavaScript,<sup>5</sup> ASP,<sup>6</sup> JSP,<sup>7</sup> PHP,<sup>8</sup> Flash,<sup>9</sup> J2EE,<sup>10</sup> XML,<sup>11</sup> por citar algunas de las más conocidas, que permiten una web mejor, más amplia, más potente, más flexible, o más fácil de mantener. Estos cambios influyen y son al tiempo influidos por la propia transformación de lo que entendemos por WWW. La generación dinámica de páginas, el acoplamiento con bases de datos, la mayor interactividad con el usuario, la concepción de la web como plataforma universal para el despliegue de aplicaciones, la adaptación al usuario, son algunas de las tendencias evolutivas más marcadas de los últimos años.

---

<sup>1</sup> <http://www.w3.org/MarkUp/>

<sup>2</sup> <http://www.w3.org/Protocols/>

<sup>3</sup> <http://hoohoo.ncsa.uiuc.edu/cgi/>

<sup>4</sup> <http://java.sun.com/>

<sup>5</sup> <http://www.mozilla.org/js/>

<sup>6</sup> <http://www.asp.net/>

<sup>7</sup> <http://java.sun.com/products/jsp/>

<sup>8</sup> <http://php.apache.org/>

<sup>9</sup> <http://www.macromedia.com/>

<sup>10</sup> <http://java.sun.com/j2ee/>

<sup>11</sup> <http://www.w3.org/XML/>

La evolución de la web no termina aquí ni mucho menos. Son diversos los aspectos susceptibles de mejorar. Entre las últimas tendencias que pueden repercutir en el futuro de la web a medio plazo, a finales de los 90 surge la visión de lo que se ha dado en llamar la *web semántica* [Berners-Lee 2001]. Se trata de una corriente, promovida por el propio inventor de la web y presidente del consorcio W3C<sup>12</sup>, cuyo último fin es lograr que las máquinas puedan entender, y por tanto utilizar, lo que la web contiene. Esta nueva web estaría poblada por agentes o representantes software capaces de navegar y realizar operaciones por nosotros para ahorrarnos trabajo y optimizar los resultados. Para conseguir esta meta, la web semántica propone describir los recursos de la web con representaciones procesables (es decir, entendibles) no sólo por personas, sino por programas que puedan asistir, representar, o reemplazar a las personas en tareas rutinarias o inabarcables para un humano. Las tecnologías de la web semántica buscan desarrollar una web más cohesionada, donde sea aún más fácil localizar, compartir e integrar información y servicios, para sacar un partido todavía mayor de los recursos disponibles en la web.

### **Un poco de historia**

La aparición de la WWW se puede situar en 1989 [Abrams 1998, Connolly 2000], cuando Tim Berners-Lee presentó su proyecto de “World Wide Web” [Berners-Lee 1989] en el CERN (Suiza), con las características esenciales que perduran en nuestros días. El propio Berners-Lee completó en 1990 el primer servidor web y el primer cliente, y un año más tarde publicó el primer borrador de las especificaciones de HTML y HTTP. El lanzamiento en 1993 de Mosaic, el primer navegador de dominio público, compatible con Unix, Windows, y Macintosh, por el *National Center for Supercomputing Applications* (NCSA), marca el momento en que la WWW se da a conocer al mundo, extendiéndose primero en universidades y laboratorios, y en cuestión de meses al público en general, iniciando el que sería su vertiginoso crecimiento. Los primeros usuarios acogieron con entusiasmo la facilidad con que se podían integrar texto y gráficos y saltar de un punto a otro del mundo en una misma interfaz, y la extrema sencillez para contribuir contenidos a una web mundial.

Por estas mismas fechas se define la interfaz CGI para la generación dinámica de páginas web, con lo que se consigue ofrecer información actualizada en tiempo real, enlazar con bases de datos, o tener en cuenta entradas del usuario, y más aún, servir como punto de acceso y plataforma para la ejecución de aplicaciones distribuidas. En 1994 miembros del equipo que creó Mosaic desarrollan Netscape, un navegador con sensibles mejoras que contribuye a impulsar la propagación de la web. Este mismo año se celebra el primer congreso internacional de la WWW, y unos meses más tarde se constituye el consorcio W3C, que desde entonces y presidido por Tim Berners-Lee, se ha hecho cargo de estandarizar las principales tecnologías web. En 1995 Sun lanza oficialmente la primera versión del lenguaje Java, y un año más tarde Netscape presenta JavaScript. Estos lenguajes y otros posteriores permiten que las propias páginas web contengan programas enteros, dando opción a una mayor autonomía respecto del servidor, mayor eficiencia, capacidad dinámica y capacidad de interacción.

---

<sup>12</sup> <http://www.w3.org/>

## La web hoy

Aunque es sumamente difícil medir el tamaño de la web, se estima que hoy día unos  $10^9$  usuarios utilizan la web, y que ésta contiene del orden de  $4 \cdot 10^9$  documentos, un volumen de información equivalente a entre 14 y 28 millones de libros [Bergman 2001]. Como dato comparativo, la asociación *American Research Libraries*, que agrupa unas 100 bibliotecas en EE.UU., tiene catalogados unos 3.7 millones de libros. La biblioteca de la Universidad de Harvard, la mayor de EE.UU., contiene en torno a 15 millones de libros. Estas cifras incluyen sólo lo que se ha dado en denominar la *web superficial*, formada por los documentos estáticos accesibles en la web. Se ha calculado que la llamada *web profunda*, constituida por las bases de datos cuyos contenidos, no directamente accesibles, se hacen visibles mediante páginas generadas dinámicamente, puede contener un tamaño de información varios cientos de veces mayor, y de mucha mejor calidad, que la web superficial, y crece a un ritmo aún mayor que ésta [O'Neill 2003]. Se estima que el tamaño de la web profunda ha superado ya al volumen total de información impresa existente en todo el planeta.

Hoy casi todo está representado de una u otra forma en la web, y con la ayuda de un buen buscador, podemos encontrar información sobre casi cualquier cosa que necesitemos. La web está cerca de convertirse en una enciclopedia universal del conocimiento humano. Por otra parte la web nos permite realizar diferentes actividades de nuestra vida diaria con una comodidad, economía y eficiencia sin precedentes: sin movernos de casa podemos comprar todo tipo de productos y servicios, gestionar una cuenta bancaria, buscar un restaurante, consultar la cartelera, leer la prensa, localizar a una persona, matricularnos en la universidad, acceder a un callejero, o trabajar desde nuestro domicilio.

No obstante, en este panorama tan favorable hay espacio para mejoras. Por ejemplo, el enorme tamaño que ha alcanzado la web, a la vez que es una de las claves de su éxito, hace que algunas tareas (por ejemplo encontrar la planificación óptima con transporte, alojamiento, etc., entre todas las posibles para un viaje bajo ciertas condiciones), requieran un tiempo excesivo para una persona o resulten sencillamente inabarcables. Desarrollar programas que realicen estas tareas en nuestro lugar es enormemente complicado, ya que es muy difícil reproducir, y más costoso aún mantener, en una máquina la capacidad de una persona para comprender los contenidos de la web tal y como están codificados actualmente.

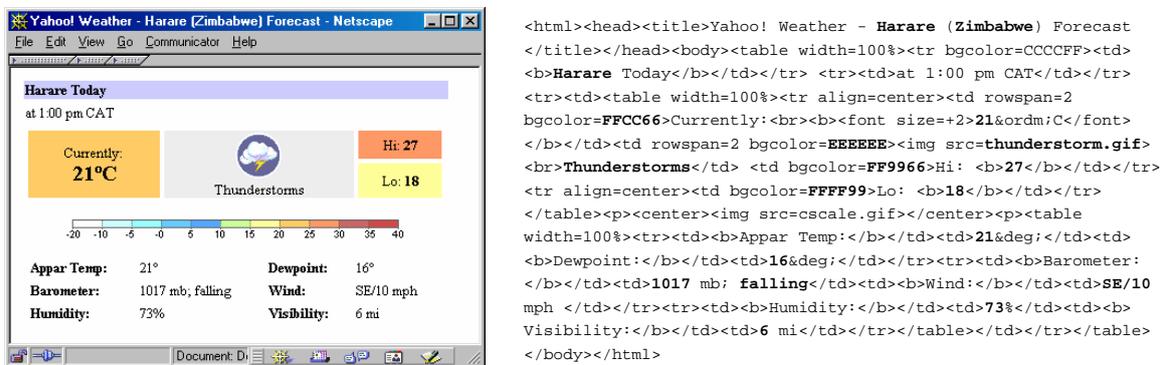
La asombrosa eficacia de los buscadores actuales tiene también sus límites. Por ejemplo, si queremos conocer la historia de Netscape, los resultados de una consulta como "Netscape history", realizada el momento de escribir este artículo<sup>13</sup>, nos informan sobre las herramientas de históricos de este navegador, pero no nos dicen nada sobre el origen y evolución de Netscape. Igualmente, para averiguar qué organismo se ocupa de estandarizar CGI, o en qué fecha apareció la primera versión de Java, necesitaremos realizar varias consultas y leer varios documentos y artículos hasta llegar indirectamente a la respuesta buscada. Si introducimos la palabra "Ketchup" para buscar información sobre el grupo de música del mismo nombre, obtendremos enlaces a restaurantes, recetas, fabricantes, distribuidores y clubes de aficionados al condimento, y finalmente lo que buscábamos (posiblemente ni siquiera esto si el grupo fuese menos popular). Si buscamos

---

<sup>13</sup> Con los continuos cambios de la web y los algoritmos de los buscadores, los resultados de estas pruebas pueden variar de un día para otro.

un “artículo sobre García Márquez”, encontraremos decenas de artículos de García Márquez, pero ninguno que trate sobre este autor. Si preguntamos sobre estándares XML para la enseñanza (“XML education”), la mayor parte de los resultados se referirán a la enseñanza de XML.

Todos estos ejemplos son el síntoma de una causa común: la falta de capacidad de las representaciones en que se basa la web actual para expresar significados. Los contenidos y servicios en la web se presentan en formatos (p.e. HTML) e interfaces (p.e. formularios) comprensibles por personas, pero no por máquinas. La figura 1 ejemplifica esta situación con una versión simplificada de una página de información meteorológica. Mientras que la presentación de los datos en el navegador (izquierda) es inmediatamente comprendida por una persona, es muy difícil para el ordenador entender cuál es la temperatura, el estado del cielo, y demás semántica del documento, al estar entremezclada con las etiquetas de formato (derecha).



a) La web vista por una persona

b) La web vista por el ordenador

**Figura 1.** La web actual está orientada al consumo humano.

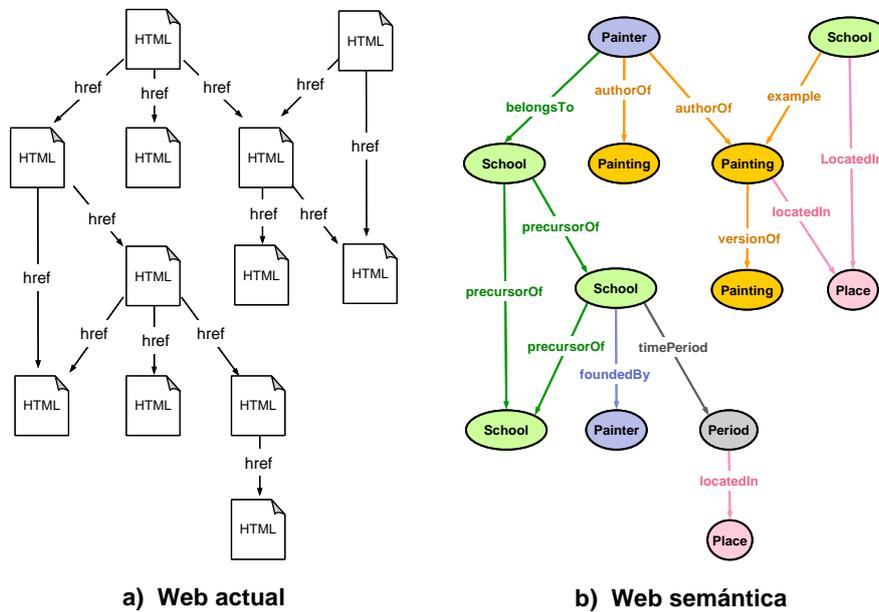
En estas condiciones es poco viable automatizar tareas mediante software en substitución del humano. Un programa puede llevar al usuario hasta lugares en la web, generar, transportar, transformar y ofrecer la información a las personas, pero la máquina sencillamente no sabe lo que esta información significa, y por tanto su capacidad de actuación autónoma es muy limitada. Esta misma limitación expresiva hace que la noción de semántica que manejan los buscadores web se limite a palabras clave con pesos, pero planas e inconexas, lo que no permite reconocer ni solicitar significados más elaborados.

### La web semántica

La web semántica<sup>14</sup> [Berners-Lee 2001] propone superar las limitaciones de la web actual mediante la introducción de descripciones explícitas del significado, la estructura interna y la estructura global de los contenidos y servicios disponibles en la WWW. Frente a la semántica implícita, el crecimiento caótico de recursos, y la ausencia de una organización clara de la web actual, la web semántica aboga por clasificar, dotar de estructura y anotar los recursos con semántica explícita procesable por máquinas. La figura 2 ilustra esta propuesta. Actualmente la web se asemeja a un grafo formado por nodos del mismo tipo, y arcos (hiperenlaces) igualmente indiferenciados. Por ejemplo, no se hace distinción

<sup>14</sup> <http://www.semanticweb.org/>, <http://www.ontology.org/>

entre la página personal de un profesor y el portal de una tienda on-line, como tampoco se distinguen explícitamente los enlaces a las asignaturas que imparte un profesor de los enlaces a sus publicaciones. Por el contrario en la web semántica cada nodo (recurso) tiene un tipo (profesor, tienda, pintor, libro), y los arcos representan relaciones explícitamente diferenciadas (pintor – obra, profesor – departamento, libro – editorial).



**Figura 2.** La web actual vs. la web semántica.

La web semántica mantiene los principios que han hecho un éxito de la web actual, como son los principios de descentralización, compartición, compatibilidad, máxima facilidad de acceso y contribución, o la apertura al crecimiento y uso no previstos de antemano. En este contexto un problema clave es alcanzar un entendimiento entre las partes que han de intervenir en la construcción y explotación de la web: usuarios, desarrolladores y programas de muy diverso perfil. La web semántica rescata la noción de ontología del campo de la Inteligencia Artificial como vehículo para cumplir este objetivo.

Gruber define ontología como “a formal explicit specification of a shared conceptualization” [Gruber 1993]. Una ontología es una jerarquía de conceptos con atributos y relaciones, que define una terminología consensuada para definir redes semánticas de unidades de información interrelacionadas. Una ontología proporciona un vocabulario de clases y relaciones para describir un dominio, poniendo el acento en la compartición del conocimiento y el consenso en la representación de éste. Por ejemplo, una ontología sobre arte podría incluir clases como *Pintor*, *Cuadro*, *Estilo* o *Museo*, y relaciones como *autor* de un cuadro, pintores *pertenecientes* a un estilo artístico u obras *localizadas* en un museo.

La idea es que la web semántica esté formada (al menos en parte) por una red de nodos tipificados e interconectados mediante clases y relaciones definidas por una ontología compartida por sus distintos autores. Por ejemplo, una vez establecida una ontología sobre cuadros y pintura, un museo virtual puede organizar sus contenidos definiendo instancias de pintores, cuadros, etc., interrelacionándolas y publicándolas en la web semántica. La adopción de ontologías comunes es clave para que todos los que participen de la web semántica, contribuyendo o consumiendo recursos, puedan trabajar de forma

autónoma con la garantía de que las piezas encajen. Así por ejemplo varios museos podrían colaborar para dar lugar a un gran meta-museo que integre los contenidos de todos ellos. Un programa que navegue por una red como ésta puede reconocer las distintas unidades de información, obtener datos específicos o razonar sobre relaciones complejas. A partir de aquí sí podemos distinguir entre un cuadro pintado por un artista y un retrato de un artista.

Por último, la web no solamente proporciona acceso a contenidos sino que también ofrece interacción y servicios (comprar un libro, reservar una plaza en un vuelo, hacer una transferencia bancaria, simular una hipoteca). Los servicios web semánticos son una línea importante de la web semántica, que propone describir no sólo información sino definir ontologías de funcionalidad y procedimientos para describir servicios web: sus entradas y salidas, las condiciones necesarias para que se puedan ejecutar, los efectos que producen, o los pasos a seguir cuando se trata de un servicio compuesto. Estas descripciones procesables por máquinas permitirían automatizar el descubrimiento, la composición, y la ejecución de servicios, así como la comunicación entre unos y otros.

### **Tecnologías para la web semántica**

La tecnología que se ha creado para hacer posible la web semántica incluye lenguajes para la representación de ontologías, parsers, lenguajes de consulta, entornos de desarrollo, módulos de gestión (almacenamiento, acceso, actualización) de ontologías, módulos de visualización, conversión de ontologías, y otras herramientas y librerías.

El primer lenguaje para la construcción de la web semántica fue SHOE<sup>15</sup>, creado por Jim Hendler en la Universidad de Maryland en 1997. Desde entonces se han definido otros lenguajes y estándares con finalidad similar, como XML, RDF<sup>16</sup>, DAML+OIL<sup>17</sup>, y más recientemente OWL<sup>18</sup>, por citar los más importantes.

XML representa una primera aproximación a la web semántica, y aunque no está expresamente pensado para definir ontologías, es el estándar más extendido hoy día en las aplicaciones de esta línea pre- web semántica. XML permite estructurar datos y documentos en forma de árboles de etiquetas con atributos. Con XML Schema<sup>19</sup> (XMLS) se pueden acordar de antemano las estructuras que se van a utilizar, así como manejar tipos de datos primitivos y derivados. Con el estándar XSLT<sup>20</sup> se pueden definir plantillas asociadas a las estructuras XML, que describen cómo generar código HTML para visualizar los contenidos en un navegador. Parsers como DOM<sup>21</sup> permiten moverse por las estructuras XML desde un programa Java o C++, y existen multitud de herramientas para facilitar la compatibilidad de XML con bases de datos, JavaBeans<sup>22</sup>, etc.

Desde la aparición de XML en 1998, se han definido multitud de estándares para modelizar información en dominios específicos como las finanzas [Coates 2001] (XBRL,

---

<sup>15</sup> <http://www.cs.umd.edu/projects/plus/SHOE/>

<sup>16</sup> <http://www.w3.org/RDF/>

<sup>17</sup> <http://www.w3.org/TR/daml+oil-reference/>

<sup>18</sup> <http://www.w3.org/2001/sw/WebOnt/>

<sup>19</sup> <http://www.w3.org/XML/Schema/>

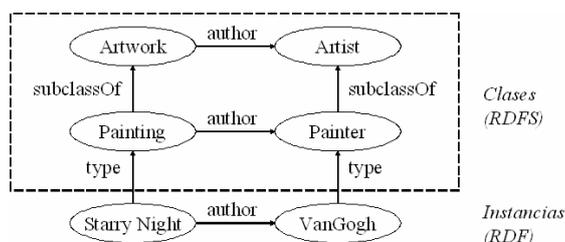
<sup>20</sup> <http://www.w3.org/Style/XSL/>

<sup>21</sup> <http://www.w3.org/DOM/>

<sup>22</sup> <http://java.sun.com/products/javabeans/>

RIXML, FpXML, ebXML, etc.), el periodismo<sup>23</sup> (p.e. NewsML, XMLNews, PRISM<sup>24</sup>), la enseñanza (SCORM,<sup>25</sup> IEEE LOM<sup>26</sup> y otros), o la medicina [Dudek 2001] (NLM Medline, SCIPHOX, CDA, etc.), entre otros muchos campos. XML es un primer paso en la dirección de avanzar hacia una representación explícita de los datos y la estructura de los contenidos de la web, separada de su presentación en HTML. XML proporciona una sintaxis para hacerlo posible, pero ofrece una capacidad limitada para expresar la semántica. El modelo de datos XML consiste en un árbol que no distingue entre objetos y relaciones, ni tiene noción de jerarquía de clases.

En 1999 se publicó la primera versión de RDF (Resource Description Framework), un lenguaje para la definición de ontologías y metadatos en la web. RDF es hoy el estándar más popular y extendido en la comunidad de la web semántica. El elemento de construcción básica en RDF es el “triple” o sentencia, que consiste en dos nodos (sujeto y objeto) unidos por un arco (predicado), donde los nodos representan recursos, y los arcos propiedades. Por ejemplo una sentencia podría expresar el hecho de que el autor (predicado) del cuadro “Starry Night” (sujeto) fue el pintor Vincent van Gogh (objeto), como se ilustra en la figura 4. Encadenando estos triples se construyen grafos o redes semánticas para la web.



**Figura 4.** RDF y RDF Schema.

Con RDF Schema (RDFS) se pueden definir jerarquías de clases de recursos, especificando las propiedades y relaciones que se admiten entre ellas (ver figura 4). En RDF las clases, relaciones, y las propias sentencias son también recursos, y por lo tanto se pueden examinar y recorrer como parte del grafo, o incluso asertar sentencias sobre ellas. Se han definido diferentes formas sintácticas para la formulación escrita de RDF, pero quizás la más extendida es la basada en XML. Es por ello que RDF se presenta a menudo como una extensión de XML. La figura 5 muestra un ejemplo simplificado de esta sintaxis.

<sup>23</sup> <http://www.iptc.org/>

<sup>24</sup> <http://www.prismstandard.org/>

<sup>25</sup> <http://www.adlnet.org/>

<sup>26</sup> <http://ltsc.ieee.org/wg12/>

```

<Painter about="vangogh" name="Vincent van Gogh"
  birth="1853" death="1890" nationality="Dutch">
  ...
</Painter>
<Painting about="starrynight" ...>
  <author resource="vangogh">
  ...
</Painting>

```

*Instancias*

---

```

<Class about="Painter">
  <subclassOf resource="Artist"/>
</Class>
<Class about="Painting">
  <subclassOf resource="Artwork"/>
</Class>
<Class about="Artist"/>
<Class about="Artwork"/>

```

*Clases*

```

<Property about="author">
  <domain resource="Artwork"/>
  <range resource="Artist"/>
</Property>

```

**Figura 5.** Sintaxis de RDF(S).

Una de las realizaciones pendientes desde hace años en relación con RDF es la creación de un lenguaje de consulta, similar al SQL de las bases de datos, que permita expresar búsquedas complejas sobre un grafo RDF mediante una sintaxis declarativa sencilla. A falta de alcanzar un acuerdo sobre un estándar comúnmente aceptado, se han consolidado de facto distintas iniciativas particulares como la del RDF Query Language<sup>27</sup> (RDQL), por Hewlett Packard, posiblemente el más extendido; RDF Schema Query Language<sup>28</sup> (RQL) [Karvounarakis 2002], por el instituto ICS-FORTH de Grecia; y Sesame RDF Query Language<sup>29</sup> (SeRQL), por la empresa holandesa Aidministrator. Por ejemplo, la siguiente consulta RDQL: “Select ?y from <gente.rdf> where (?x, <edad>, ?z), (?x, <nombre>, ?y) and ?z > 17” devolvería la propiedad “nombre” de todos los recursos del grafo definido en “gente.rdf” cuya propiedad “edad” tiene un valor mayor que 17.

A RDF le siguieron OIL<sup>30</sup> (Ontology Inference Language), desarrollado en Europa, y DAML<sup>31</sup> (DARPA Agent Markup Language), en EE.UU., dos lenguajes muy similares que de hecho se terminaron fundiendo en DAML+OIL. A partir de esta unión se definió el lenguaje OWL (Web Ontology Language), con el propósito de reunir todas las ventajas de DAML+OIL y resolver los problemas de este lenguaje. OWL se puede formular en RDF, por lo que se suele considerar una extensión de éste. OWL incluye toda la capacidad expresiva de RDF(S) y la extiende con la posibilidad de utilizar expresiones lógicas. OWL permite, por ejemplo, definir clases mediante condiciones sobre sus miembros (p.e. la clase de los cuadros creados por pintores españoles), mediante combinación booleana de clases (*Tinto* and *Rioja* and not *Crianza* en una ontología de vinos), o por enumeración de las instancias que pertenecen a la clase (i.e. por extensión). Además OWL permite atribuir ciertas propiedades a las relaciones, como cardinalidad, simetría, transitividad, o relaciones inversas. Si bien RDF y OWL son hoy en día los lenguajes más consolidados, existen otros lenguajes interesantes, aunque con menos usuarios, como TopicMaps,<sup>32</sup> OCML<sup>33</sup> o WebODE.<sup>34</sup>

<sup>27</sup> <http://www.hpl.hp.com/semweb/rdql.htm>

<sup>28</sup> <http://139.91.183.30:9090/RDF/RQL/>

<sup>29</sup> <http://sesame.aidministrator.nl/publications/users/ch05.html>

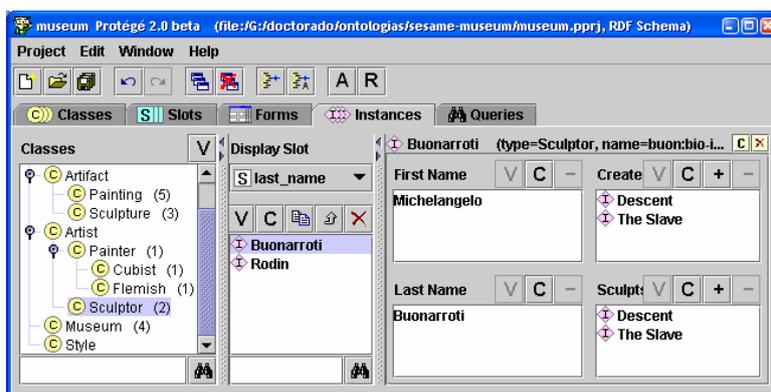
<sup>30</sup> <http://www.ontoknowledge.org/oil/>

<sup>31</sup> <http://www.daml.org/>

<sup>32</sup> <http://www.topicmaps.org/>

Para desarrollar aplicaciones basadas en RDF, OWL o lenguajes similares se precisan librerías para leer y procesar las ontologías definidas en estos lenguajes. Basta dar un vistazo a esta lista de recursos RDF: <http://www.ilt.bristol.ac.uk/discovery/rdf/resources/#sec-tools>, para comprobar la multitud de parsers y herramientas que se han desarrollado al efecto. Sin embargo con diferencia el parser de RDF y OWL más popular es Jena<sup>35</sup>, desarrollado por Hewlett Packard, que permite leer, recorrer y modificar grafos tanto RDF como OWL desde un programa Java. Jena permite además guardar las ontologías tanto en RDF textual como en formato de base de datos, lo que es importante para grafos muy grandes. Otra librería muy conocida de similares características para RDF y OWL es Sesame<sup>36</sup>, desarrollado en el proyecto europeo Ontoknowledge<sup>37</sup> y actualmente distribuido por AIdministratoR. Jena incluye además un motor de consultas para RDQL, y Sesame ofrece lo propio para RQL y SeRQL. Las últimas versiones de Jena y Sesame han incorporado también motores de razonamiento para las expresiones lógicas de OWL.

Escribir en lenguajes como RDF y OWL resulta sumamente difícil y propenso a errores. Afortunadamente se pueden utilizar entornos gráficos para visualizar y construir ontologías de forma mucho más razonable, como Kaon<sup>38</sup>, WebODE o Protégé<sup>39</sup>. De todas ellas Protégé, desarrollada por el *Stanford Medical Informatics* de la Universidad de Stanford, es la herramienta de construcción de ontologías que más usuarios tiene actualmente. Con ella se puede fácilmente crear clases y jerarquías, declarar propiedades para las clases, crear instancias e introducir valores, todo ello en un entorno de menús, botones, cuadros de diálogo y representaciones gráficas fáciles de usar. La figura 6 muestra una pequeña ontología para museos con algunas instancias de obras y artistas. Protégé tiene su propio lenguaje interno para definir ontologías, pero permite también trabajar con RDF y OWL de modo transparente. Protégé es un entorno abierto y fácil de extender, que ha generado en torno suyo toda una comunidad que contribuye activamente a ampliar el entorno con todo tipo de contribuciones en forma de plug-ins, y está haciendo de esta herramienta un entorno sumamente potente.



**Figura 6.** El entorno de desarrollo Protégé.

<sup>33</sup> <http://kmi.open.ac.uk/projects/ocml/>

<sup>34</sup> <http://delicias.dia.fi.upm.es/webODE/>

<sup>35</sup> <http://www.hpl.hp.com/semweb/jena2.htm>

<sup>36</sup> <http://sesame.aidministratoR.nl/>

<sup>37</sup> <http://ontoknowledge.semanticweb.org/>

<sup>38</sup> <http://kaon.semanticweb.org/>

<sup>39</sup> <http://protege.semanticweb.org/>

Por lo que respecta a los servicios web, entre los estándares ya asentados, basados en XML, podemos citar el lenguaje WSDL<sup>40</sup> (Web Service Description Language) para la descripción de servicios; el protocolo SOAP<sup>41</sup> (Simple Object Access Protocol) para el intercambio de mensajes entre servicios; y el sistema de directorio UDDI<sup>42</sup> (Universal Description, Discovery and Integration) para localizar servicios dinámicamente. BPEL4WS<sup>43</sup> (Business Process Execution Language for Web Services), desarrollado por IBM, añade a WSDL descripciones para coordinar el flujo de operaciones en procesos de negocios y transacciones. Los servicios web están despertando un gran interés no sólo en el entorno académico sino también por parte de la industria. Así lo demuestra el hecho de que tanto la nueva Java 2 Enterprise Edition (J2EE) de Sun, como la plataforma .NET<sup>44</sup> de Microsoft incluyen herramientas para desarrollar y ejecutar servicios web, y empresas tan importantes como IBM, SAP o Microsoft están ofreciendo registros UDDI.

Los servicios web semánticos proponen extender estas tecnologías, en vías de consolidación, con ontologías y semántica que permitan la selección, integración e invocación dinámica de servicios, dotándoles así mismo de la capacidad de reconfigurarse dinámicamente para adaptarse a los cambios (p.e. interrupción de servicios o aparición de otros más adecuados) sin intervención humana. La iniciativa más tangible en este sentido, DAML-S<sup>45</sup> (DAML for Services) y su sucesor OWL-S<sup>46</sup>, ha propuesto una ontología para la descripción de la semántica de servicios, pero aún no han dado lugar a una implementación de las plataformas y motores necesarios para la ejecución de los servicios.

### **De la web actual a la web semántica**

Llegados a este punto una pregunta importante a responder es cómo encaja la web semántica con la actual, es decir a) cómo accederá el usuario a la web semántica, y sobre todo, b) cómo hacer la transición de la web actual a la web semántica. Para que la web semántica pueda realizarse es importante que guarde, al menos al principio, una compatibilidad con la tecnología actual. Es deseable por ejemplo mantener HTML (u otros lenguajes compatibles con los navegadores actuales) como vehículo de comunicación con el usuario. La asociación entre las instancias de la web semántica y el código HTML se puede establecer de distintas maneras (ver figura 3). Una consiste en conservar los documentos actuales, y crear las instancias asociadas anotando su correspondencia con los documentos (imagen izquierda en la figura 3). Esta posibilidad es la más viable cuando se parte de un gran volumen de material antiguo. Otra es generar dinámicamente páginas web a partir de las ontologías y sus instancias (imagen derecha). Esta última opción puede resultar factible cuando los documentos antiguos ya se estaban generando automáticamente a partir, por ejemplo, de una base de datos.

---

<sup>40</sup> <http://www.w3.org/TR/wsdl/>

<sup>41</sup> <http://www.w3.org/2000/xml/Group/>

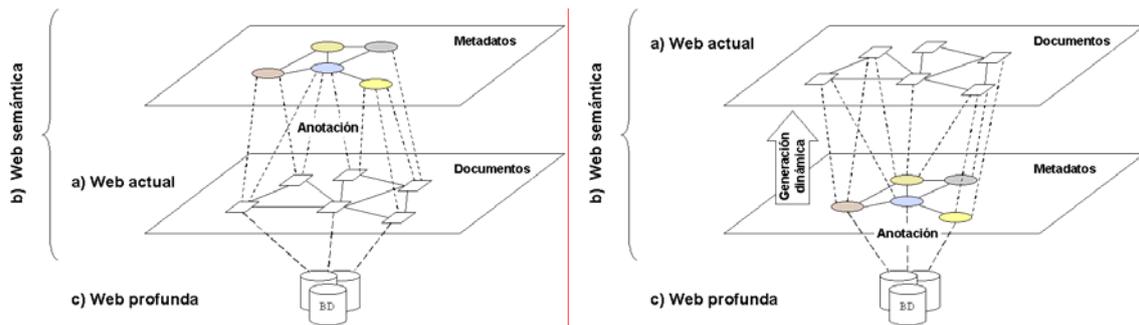
<sup>42</sup> <http://www.uddi.org/>

<sup>43</sup> <http://www-106.ibm.com/developerworks/webservices/library/ws-bpel/>

<sup>44</sup> <http://www.microsoft.com/net/>

<sup>45</sup> <http://www.daml.org/services/>

<sup>46</sup> <http://www.daml.org/services/owl-s/1.0/>



**Figura 3.** De la web actual a la web semántica.

La transición de la web actual a la web semántica puede implicar un coste altísimo si tenemos en cuenta el volumen de contenidos que ya forman parte de la web. Crear y poblar ontologías supone un esfuerzo extra que puede resultar tedioso cuando se agregan nuevos contenidos, pero directamente prohibitivo por lo que respecta a integrar los miles de gigabytes de contenidos antiguos. Las estrategias más viables combinan una pequeña parte de trabajo manual con la automatización del resto del proceso. Las técnicas para la automatización incluyen, entre otras, el mapeo de la estructura de bases de datos a ontologías, el aprovechamiento, previa conversión, de los metadatos y estándares de clasificación presentes en la web (y fuera de ella), y la extracción automática de metadatos a partir de texto y recursos multimedia.

Otra dificultad importante a la hora de realizar la web semántica en la práctica es la de consensuar ontologías en una comunidad por poco amplia que sea. Converger a una representación común es una labor más compleja de lo que puede parecer, ya que típicamente cada parte del sistema conlleva peculiaridades necesarias, y un punto de vista propio que a menudo necesitan incidir en la propia ontología. La representación del mundo no es neutra respecto al uso que se le va a dar: tanto un dietista como un biólogo tienen conocimiento sobre las plantas, pero su representación de esa materia es muy distinta, y probablemente no sería adecuado imponer la misma representación para ambas perspectivas. Las vías para salvar esta dificultad consisten en compartir ontologías para las áreas comunes en que puede tener lugar una interacción o intercambio de información entre las partes, y establecer formas de compatibilidad con las ontologías locales, mediante extensión y especialización de las ontologías genéricas, o por mapeo y exportación entre ontologías.

### La web semántica hoy

Los resultados alcanzados hasta ahora hacia la realización de la web semántica son muy preliminares si se mira desde la óptica más ambiciosa, la de la adopción universal de la web semántica. Se ha avanzado mucho con las herramientas, los estándares y la infraestructura necesarios para el despliegue de la web semántica, y se han desarrollado proyectos y experiencias piloto para poner a prueba las herramientas y las ideas. En este punto, el desarrollo de aplicaciones reales basadas en esta tecnología se ha identificado como una realización necesaria para que la web semántica prospere [Haustein 2002].

Existe un gran interés desde el entorno corporativo, el sector público y el mundo académico por hacer de la web semántica una realidad, ya que se piensa que puede ser una pieza importante para el progreso de la sociedad de la información. Las grandes agencias de financiación pública (programas marco EU-IST en Europa, DARPA en

EE.UU.) incluyen áreas prioritarias específicas dedicadas a la web semántica, y están invirtiendo grandes presupuestos en proyectos de investigación y desarrollo en este campo (la última llamada del VI Programa Marco ha destinado más de 60.000 millones de euros al área “Semantic-based Knowledge Systems” para los próximos cuatro años). Las principales empresas (IBM, Microsoft, Sun, Oracle, BEA, SAP, HP...) están participando activamente en el desarrollo de los estándares y tecnologías.

La web semántica se ha convertido en un área de investigación de moda en los centros de investigación de todo el mundo, entre ellos el MIT, la Universidad de Stanford, la Universidad de Maryland, la Universidad de Innsbruck (Austria), la Universidad de Karlsruhe (Alemania), la Universidad de Manchester, la Open University en el Reino Unido, por citar tan sólo algunos de los grupos más destacados. También en la Universidad Autónoma de Madrid se están llevando a cabo proyectos en esta área.<sup>47</sup> En pocos años se ha consolidado una comunidad investigadora considerable, de cuyo reflejo cabe destacar un gran congreso internacional que se celebra con carácter anual (*International Semantic Web Conference*<sup>48</sup>), y revistas como el *Journal of Web Semantics*,<sup>49</sup> o el área *The Semantic Web* de *Electronic Transactions on Artificial Intelligence*<sup>50</sup> (ETAI). Es muy de destacar así mismo el apoyo y el importante papel del W3C en el proyecto de la web semántica, con la creación de grandes y muy activos grupos de trabajo para el desarrollo de esta área, y muy en especial liderando el esfuerzo de estandarización de lenguajes y tecnologías específicas para la web semántica.

Aún queda mucho trabajo por hacer. Se necesita crear más y mejor tecnología e infraestructura, y más aún, desarrollar aplicaciones reales que pongan en práctica los principios de la web semántica, que pueblen la web con ontologías, y que hagan que la web semántica adquiera la masa crítica imprescindible para hacerse realidad. En espera de que se alcance esta meta y al margen de ese debate, se han desarrollado ideas muy aprovechables a niveles específicos, y se han abierto nuevos campos para la innovación, suficientemente interesantes para motivar la investigación en esta área.

## **Bibliografía**

[Abrams 1998] M. Abrams, ed., World Wide Web - Beyond the Basics, Prentice Hall, 1998. Versión on-line disponible en <http://ei.cs.vt.edu/~wwwwtb/book/>.

[Bergman 2001] M. K. Bergman. The Deep Web: Surfacing Hidden Value. The Journal of Electronic Publishing. Volume 7, Issue 1, August, 2001. Disponible en <http://www.press.umich.edu/jep/07-01/bergman.html>.

[Berners-Lee 1989] T. Berners-Lee. Information Management: A Proposal. Internal Project Proposal, CERN, 1989. Disponible en <http://www.w3.org/History/1989/proposal.html>.

[Berners-Lee 2001] T. Berners-Lee, J. Hendler, O Lassila. The Semantic Web. Scientific American, May 2001.

[Coates 2001] A. B. Coates. The Role of XML in Finance. XML Conference & Exposition 2001. Orlando, Florida, December 2001.

---

<sup>47</sup> <http://seweb.ii.uam.es/>

<sup>48</sup> <http://iswc.semanticweb.org/>

<sup>49</sup> <http://www.elsevier.com/locate/websem/>

<sup>50</sup> <http://www.etaij.org/seweb/>

[Connolly 2000] D. Connolly. A Little History of the World Wide Web. W3C Consortium, 2000. Disponible en <http://www.w3.org/History.html>.

[Dudek 2001] J. Dudek. XML in Health Care. XML Europe 2001. Berlin, Alemania, 2001.

[Gruber 1993] T. R. Gruber. A Translation Approach to Portable Ontology Specifications. Knowledge Acquisition, 5(2), pp. 199-220, 1993.

[Haustein, 2002] S. Haustein and J. Pleumann. Is Participation in the Semantic Web too Difficult? International Semantic Web Conference (ISWC'2002). Cerdeña, Italia, 2002.

[Karvounarakis 2002] G. Karvounarakis, S. Alexaki, V. Christophides, D. Plexousakis, M. Scholl. RQL: A Declarative Query Language for RDF. 11<sup>th</sup> International World Wide Web Conference (WWW2002), 2002.

[O'Neill 2003] E. T. O'Neill, B. F. Lavoie, R. Bennett. Trends in the Evolution of the Public Web. D-Lib Magazine, Volume 9 Number 4, April 2003. Disponible en <http://www.dlib.org/dlib/april03/lavoie/04lavoie.html>.