

Verso il *semantic web*

La tappa italiana del "W3C Semantic Tour"

Lo scorso 10 giugno si è svolta a Roma, presso l'Università Gregoriana, la tappa italiana del "W3C Semantic Tour", un'iniziativa del World Wide Web Consortium (W3C) che nel giugno 2003 ha organizzato una serie di eventi della durata di un giorno in tutta Europa allo scopo di promuovere le tecnologie W3C, sottolineando il fatto che il web ha ormai dati ben definiti e linkati in modo da permettere una discovery più efficace, l'automazione, l'integrazione e il riutilizzo in diverse applicazioni.

Stando alla definizione di Tim Berners-Lee, inventore del World Wide Web e direttore del consorzio, il *semantic web* "is an extension of the current web in which information is given well-defined meaning, better enabling computers and people to work in cooperation."¹

L'organizzazione a livello locale è stata curata dall'Ufficio W3C italiano, situato presso l'Istituto di scienza e tecnologie dell'informazione "A. Faedo" (ISTI) del CNR a Pisa.


Gli interventi più interessanti sono stati presentati nell'arco della mattinata, a cominciare da Daniel Dardailier (W3C associate chairman for Europe) che dopo aver presentato il consorzio, creato nell'ottobre del 1994 per portare il World Wide Web al pieno potenziale sviluppando protocolli comuni che ne promuovessero l'evoluzione e assicurassero l'interoperabilità,² ha illu-

strato la *mission*, le attività e il modello organizzativo, in particolare la distribuzione di uffici e host nel mondo. Massimo Marchiori (W3C-MIT) ha quindi introdotto il concetto di *semantic web*, partendo dal fatto che il passaggio all'XML non rappresenta la risoluzione del problema di un recupero efficace dell'informazione. Il *semantic web* è orientato all'accesso e a una migliore semantica: l'attuale modello di ricerca (diretta o locale) non funziona più dal momento che l'utente vuole accedere ai dati e avere il documento. I *web services*,³ architetture di base SOA (Service Oriented Architecture)⁴ rappresentano una soluzione allettante ma la necessità attuale è introdurre più semantica. La grande flessibilità dell'XML può rivelarsi in realtà un'arma a doppio taglio poiché la proliferazione di dialetti XML può portare a problemi di interoperabilità, causando l'effetto cosiddetto *lost in translation*.⁵ In uno schema che descrive l'architettura del web possiamo definire RDF (Resource Description Framework) come il mattone principale, il linguaggio unico, che precisa la semantica delle risorse descritte nelle diverse comunità di utilizzatori di metadati. Come XML, RDF è un linguaggio estensibile, un metalinguaggio, è una cornice (*framework*) di descrizione delle risorse usabile indipendentemente dal dominio di applicazione. Un'applicazione interessante è Anno-

tea,⁶ un progetto del W3C che ha prodotto un sistema di annotazioni condivise delle pagine web, ossia commenti, note, spiegazioni o altri tipi di osservazioni esterne che possono essere "attaccate" (possiamo assimilarlo all'uso che facciamo normalmente dei foglietti post-it ma immaginandoli come oggetti dinamici) a un qualsiasi documento web senza alcuna necessità di toccare il documento. Per descrivere annotazioni come i metadati, Annotea usa uno schema di annotazioni basato su RDF che gestisce sia l'annotazione sia i dati ad essa relativi.⁷ Gli equivoci che scaturiscono dalle attuali applicazioni semantiche sono innumerevoli se ci basiamo sulla natura monotona di RDF:⁸ partendo dal principio che se si crede all'insieme, si crede anche alle sottocomponenti, possono scaturire problemi interpretativi di una certa consistenza.

Altra tecnologia di recente sviluppo legata a RDF è Web Ontology Language (OWL),⁹ usato per descrivere ontologie (classificazioni), concetti (classi e sotto-classi), equivalenze. Un'ontologia definisce i termini usati per descrivere e rappresentare un'area della conoscenza: includono definizioni di concetti base di un dominio (ossia un'area di

conoscenza specifica) usabili dalle macchine e le relazioni tra essi, codificando la conoscenza in uno o più domini e rendendola pertanto riutilizzabile. Si tratta di rappresentazioni tipo le tassonomie (ad es. la gerarchia di Yahoo), gli schemi di metadati (come il Dublin Core) o teorie logiche. Il *semantic web* ha bisogno di ontologie con un livello strutturale significativo. OWL presenta una struttura a tre livelli: le *Classi* (cose generiche) nei molti domini di interesse; le *Relazioni* che possono esistere tra esse e le *Proprietà* (o attributi) che tali cose possono avere. Le ontologie sono dunque uno strumento per accordarsi in modo preciso sul significato dei termini utilizzati in un certo contesto e sulle relazioni che intercorrono tra questi termini. Lo schema RDF fornisce lo strumento per definire il vocabolario, la struttura e i vincoli per esprimere metadati relativi alle risorse web. Uno stesso concetto può avere diverse URI di riferimento e l'utilità dell'URI decresce in base al numero delle varianti: OWL riduce questo problema grazie alla possibilità di stabilire relazioni tra ontologie, agendo come "traduttore" a livello superiore RDF. Senza un'appropriata informazione semantica le forme di aggiornamento automatico fal-



liscono e potrebbero trarre notevole vantaggio dal *semantic web*. Un esempio di applicazione avanzata è Closed World Machine (CWM) sviluppato qualche tempo fa da Tim Berners-Lee, un data processor che utilizza il linguaggio RDF/XML e può essere usato per richiedere, controllare, trasformare e filtrare l'informazione. RDF rappresenta comunque solo il primo passo verso quello che proprio Tim Berners-Lee chiama *semantic web*, un World Wide Web dove i dati sono strutturati e gli utenti possono pienamente beneficiare di questa struttura quando accedono all'informazione sul web. In realtà RDF fornisce il vocabolario base in cui i dati possono essere espressi e strutturati: il problema dell'accesso e della gestione di questi dati resta. *Meta-log*¹⁰ fornisce una vista "logica" dei metadati presenti sul web. L'approccio è composto da tre livelli (modello, logica, sintassi). Al vertice del modello del web presentato da Marchiori c'è la fiducia: ci si può fidare dell'informazione recuperata tramite queste applicazioni innovative? Troppo web semantico può trarre in inganno, se se ne fa un uso non corretto. L'informazione sul web non è trasparente, piuttosto è soggetta a diversi tipi di cosiddette fratture quali i criteri per influenzare il ranking dei motori di ricerca, le *pop-up windows* o i *web-bugs*.¹¹ Un breve cenno è stato fatto dal relatore allo standard Topic Maps¹² (ISO 13250 pubblicato nel gennaio 2000) definito in effetti uno sforzo parallelo al *semantic web*, frutto di due attività diverse ma con obiettivi molto simili: anche le *topic maps* sono infatti una rappresentazione

della struttura della conoscenza volta a risolvere i problemi legati alla gestione dell'informazione nel creare, mantenere ed elaborare indici di documentazione complessa. Secondo la specifica XML Topic Maps (XTM) 1.0 lo scopo di una *topic map* è far convergere la conoscenza delle risorse attraverso uno strato sovrapposto, o mappa, delle risorse: una *topic map* cattura i soggetti delle risorse di cui parla e le relazioni tra i soggetti in modo indipendente dall'implementazione. Nicola Guarino del Laboratory for Applied Ontology (LOA)¹³ ha presentato una lunga relazione dedicata alle ontologie e al loro ruolo nel *semantic web*. Concorrendo sul fatto che XML è solo il primo passo, dal punto di vista sintattico, e che i vocabolari standard rappresentano un ulteriore passo avanti (nonostante le difficoltà che comportano nella costruzione, nell'aggiornamento e nella comprensione da parte degli utenti) ha ribadito la necessità delle ontologie che vanno ben oltre le liste di vocabolari standard. Distanziandosi innanzitutto dal concetto filosofico, egli definisce l'ontologia nell'ambito dell'Information Technology come un artefatto, un oggetto progettato per esprimere il significato *inteso* di un vocabolario condiviso. La posizione di Guarino si rivela ancora molto legata al concetto di database e infatti delinea il ruolo delle ontologie nel *semantic web* come finalizzate all'interoperabilità semantica e all'information retrieval. L'ontologia è una concettualizzazione, una struttura formale della realtà così come è interpretata da un agente, indipendentemente dal voca-

bolario usato e dalla attuale occorrenza di una specifica situazione. La funzione dell'ontologia è dunque principalmente quella di catturare il significato *inteso* di un vocabolario secondo una concettualizzazione: si tratta di una teoria logica i cui modelli catturano il più possibile i modelli intesi. Qual è dunque la differenza tra le ontologie e i vecchi modelli concettuali? In effetti, secondo Guarino, non è tanta, poiché le ontologie rappresentano modelli concettuali più raffinati e con alcune attenzioni particolari (i modelli non sono accessibili *run time* e non hanno una semantica formale). Nel modello vengono specificati solo i vincoli importanti per le *queries*, mentre nelle ontologie si tiene conto dei vincoli necessari per il significato inteso. Tra ontologie e base di conoscenza più che differenze esiste un rapporto di inclusione, poiché la base di conoscenza consta di due componenti, asserzionale e terminologica, e quest'ultima di fatto è un'ontologia. Le formule ontologiche devono essere assunte sempre come valide, in tutte le situazioni. Per verificare la qualità di un'ontologia ci rifacciamo ai concetti di precisione e di copertura (rispetto a tutti i modelli presenti). Nell'insieme dei modelli che più si avvicinano alle ontologie: i glossari, i thesauri, gli schemi di Database Object Oriented e le tassonomie, queste ultime ritenute le più somiglianti come livello di precisione, comunque inferiore rispetto a quello delle ontologie. Un'ulteriore dimensione di valutazione è l'accuratezza, basata sull'esclusione di situazioni non intese.¹⁴ La qualità dell'ontologia è dunque legata ai

valori di consistenza (almeno locale), copertura, precisione e accuratezza. Per valutare, comparare e certificare le ontologie è necessario un *framework* rigoroso. Un altro aspetto importante è la trasparenza cognitiva, poiché bisogna che le ontologie risultino comprensibili. Delle ontologie vengono fatti diversi usi: – *Semplice accesso semantico*. Il significato dei termini è conosciuto a priori dalla comunità di utilizzo, l'espressività è limitata e la navigazione all'interno dell'ontologia veloce. – *Negoziazione*. Siamo al di fuori di una comunità ristretta che condivide i significati, come nel caso del web: un'immensa comunità eterogenea che richiede linguaggi più sofisticati. In questo caso il ruolo delle ontologie fondazionali (o generali) è determinante perché esse pongono una struttura tassonomica robusta, aiutano a capire gli *agreements* e i falsi *agreements* migliorando la fiducia nei *web services*. Alcuni esempi di queste realtà sono il progetto WonderWeb Library of Foundational Ontologies (WFO) che ha un approccio interdisciplinare a un'ontologia unificata di modellazione, nessun singolo livello superiore ma piuttosto un piccolo set di ontologie fondazionali e il progetto Descriptive Ontology for Linguistic and Cognitive Engineering (DOLCE) primo modulo di riferimento per la Foundational Ontology Library che vede le categorie come contenitori concettuali piuttosto che come profonde implicazioni metafisiche. È legato a Word Net,¹⁵ un database lessicale online per la lingua inglese sviluppato presso il Cognitive Science Laboratory

alla Princeton University. A questo punto è lecito chiedersi se il *semantic web* non sia piuttosto una trovata pubblicitaria per catturare l'interesse: di fatto un vocabolario ontologico da solo non basta, sono necessarie primitive ontologi tipo quelle di OWL ma anche queste non sono sufficienti. In questo campo l'Europa è piuttosto avanti, più degli USA, a detta di Guarino, e la stessa Italia vanta l'organizzazione della prima conferenza sul ruolo delle ontologie negli Information Systems nel 1998.¹⁶

L'intervento di Michele Misikoff, previsto dal programma, è stato tenuto da Francesco Taglino, sul web semantico nelle applicazioni di impresa, focalizzato sull'interoperabilità semantica e le ontologie di impresa. Nella visione di un approccio ontologico per la cooperazione tra imprese finalizzata alla cooperazione tra sistemi informativi eterogenei, il progetto europeo Harmonise¹⁷ mira a costruire un'infrastruttura basata su un'ontologia condivisa nel

settore turistico. In particolare il progetto ha investigato su tre aree principali, classificando i problemi di interoperabilità causati dalle differenze degli schemi concettuali di due applicazioni che tentano di cooperare in due gruppi:

1) *lossless clashes* che possono essere risolte senza perdita di informazione (per es. relative al *naming* quando la stessa informazione è rappresentata da due etichette diverse, o differenze strutturali quando gli elementi dell'informazione sono raggruppati in modi diversi, e infine differenze di unità quando un valore scolare, tipo una quantità di denaro, è espresso con unità di misura diverse);

2) *lossy clashes* che comportano perdita di informazione, come nel caso di diversi livelli di granularità, raffinamento e precisione (per esempio nell'esprimere una distanza si può utilizzare *near* o un valore in miglia o nella precisazione relativa, nel caso di un hotel, al numero delle camere e al numero dei letti in un altro).

L'ontologia rappresenta una vista comune del dominio di applicazione, usata per dare significato alle strutture informative scambiate tra applicazioni. Il linguaggio utilizzato in Harmonise è OPAL (Object, Process, Actor Modelling Language) su cui è stato sviluppato l'*ontology management system* SymOntoX. Il concetto di ontologia di dominio viene rappresentato come una castagna divisa in senso verticale in tre aree: il livello superiore (*upper domain ontology*) contiene concetti generici (per es. evento), nella parte inferiore (*lower domain ontology*) concetti elementari (per es. prezzo, costo, indirizzo Internet). Il nucleo centrale (*application ontology*) è il più complesso perché i concetti e le definizioni dipendono dalla specifica applicazione, il problem solving messo in atto e la tecnologia sottostante, oltre agli aspetti culturali (per es. concetto di cliente, fattura, sconto o concetti più legati al settore specifico, nel caso di Harmonise il turismo). L'annotazione semantica nella rappresentazione del significato di uno schema concettuale locale viene espressa usando i concetti dell'ontologia che fornisce un unico riferimento semantico per ogni applicazione. Tali annotazioni semantiche vengono utilizzate per generare la mappatura tra schema concettuale locale e ontologia di riferimento.

Dall'intervento di Jeremy J. Carroll (HP Labs) è emerso un punto di vista piuttosto critico nei confronti del *semantic web*, sottolineandone la natura di puro investimento, allo stato attuale, in vista di ritorni futuri piuttosto incerti. Il gruppo di ricerca dei laboratori Hewlett

Packard riconosce a questa tecnologia la potenzialità di rendere più flessibile l'approccio all'integrazione dei dati, ai *web services* e alla scoperta della conoscenza. Pertanto collabora con il W3C alla definizione di standard per supportare la crescita del web semantico, allo sviluppo di tool per sviluppatori che facilitino le implementazioni relative al *semantic web* e ne valorizzino il significato e le potenzialità. Jena rappresenta la piattaforma principale di HP per il web semantico: si tratta di un *toolkit* in Java per sviluppare applicazioni per il web semantico in base alle raccomandazioni del W3C per RDF e OWL (<http://www.w3.org/TR/webontreq/>), utile per la manipolazione di entità e modelli RDF.¹⁸ Investire nel *semantic web* comporta dei rischi, rappresentati in primo luogo dalla *critical mass*: attualmente i costi sono più dei vantaggi, e in qualsiasi tipo di network la partecipazione al *semantic web* è un atto di fede poiché siamo ancora agli inizi mentre la crescita di questo fenomeno è esponenziale. Altro rischio o l'interoperabilità semantica: attraverso il *semantic web* è possibile realizzare cooperazione tra i modelli concettuali di applicazioni diverse, ma al momento non c'è abbastanza esperienza per poter affermare che il sistema *semantic web*-ontologie funziona. Infine consideriamo che esistono sistemi cosiddetti *neats* (formali e ben precisi) e *scruff* (sciatti): i primi, pur fornendo garanzie, hanno un'espressività limitata mentre il mondo reale non è così pulito e preciso. Il secondo tipo comporta maggiore difficoltà di composizione a vantaggio di una espressivi-

