

Thomas Risse

Resum de la ponència:

El web s'ha consolidat com a suport de comunicació i d'informació a tot el món. Les noves tecnologies n'amplien constantment l'ús i permeten, així mateix, que usuaris sense experiència puguin publicar contingut o contribuir en debats. Per tant, es considera que el web és una bona font de documentació de la societat actual i l'arxivament i la conservació web s'han convertit en una necessitat cultural per conservar el coneixement. Aquest és precisament el cas de les publicacions digitals no tradicionals, com les xarxes socials, els espais de col·laboració o els llibres de laboratori digitals. El repte que plantegen les noves formes de publicació és que pot haver-hi una manca d'alineació entre el que les institucions consideren que val la pena conservar, el que els propietaris veuen com a valor actual i l'incentiu per conservar juntament amb la rapidesa amb què cal prendre les decisions. Per a les publicacions efímeres com les del web, sovint aquesta manca d'alineació dóna lloc a pèrdues irreparables. Atesa la immensa quantitat d'informació digital creada i aquesta situació d'incertesa, un dels primers passos que caldria fer és poder respondre amb rapidesa, encara que sigui de manera preliminar, per la creació oportuna d'arxius, amb una despesa general mínima que permeti accions de conservació més costoses més endavant.

Un factor fonamental per permetre una nova generació d'arxius web són les aranyes web (també conegudes com a rastrejadors o *crawlers*). Les aranyes web són programes complexos que, tanmateix, implanten un procés ben senzill: seguir enllaços i recuperar pàgines web. Al costat de la recol·lecció clàssica orientada a dominis, es pot observar un interès creixent pels sistemes de rastreig actuals i pel seu estudi des de disciplines científiques diferents. La tecnologia web actual de *crawlers* s'inspira o es basa principalment en *crawlers* per a motors de cerca. Per això, tenen una idea limitada o nul·la sobre el context de temes, entitats, esdeveniments o el web social. En aquesta ponència ens agradaria presentar l'arquitectura d'un nou tipus de *crawler* que analitzarà i extraurà el ric teixit social del web social per trobar indicis que ens ajudin a decidir què és el que s'ha de conservar (basant-nos en el reflex que generen al web social), per contextualitzar el contingut dels arxius digitals a partir del seu context al web social i determinar la millor manera de conservar aquest context. A més de l'estratègia amb *crawlers*, abordarem alguns dels reptes que plantegen les noves tecnologies, com el JavaScript o els objectes incrustats.

Pel fet que la comunitat d'arxius web tan sols ha fet una primera aproximació a les qüestions de rastreig i conservació de contingut web, l'ús d'arxius web encara es troba en els seus inicis. No obstant això, nombroses disciplines, com les ciències socials, la ciència històrica i el dret, així com el periodisme o el màrqueting, mostren cada vegada més interès per l'ús d'arxius web. A la segona part de la ponència comentarem alguns escenaris d'ús i limitacions de les eines existents. Així mateix, repassarem el treball de recerca actual que es duu a terme en el context de la subvenció Alexandria del Consell Europeu de Recerca (ERC 339.233), que té per objecte desenvolupar models, eines i tècniques necessàries per explorar i analitzar arxius web a través del temps d'una manera significativa.