
Sistema per protegir la privadesa dels usuaris dels motors de cerca d'Internet

Rubén Salvador Gareta
Enginyeria en Informàtica

Jordi Castellà-Roca

Desembre 2011

Índex

- Introducció
 - Objectius
 - Justificació
 - Planificació del projecte
 - Descripció de l'esquema
 - Disseny de la implementació
 - Implementació
 - Marc d'avaluació
 - Resultats
 - Conclusions
-

Introducció

- Molts dels usuaris dels motors de cerca d'Internet realitzen cerques sobre els seus interessos, la seva persona, la seva feina, els seus problemes, etc.
 - Aquesta informació queda emmagatzemada en l'historial de cerques del perfil de cada usuari dins del motor de cerca per facilitar que el cercador serveixi la informació més ràpidament.
 - Aquesta informació conté dades personals i privades que permeten identificar unívocament la identitat dels usuaris perdent d'aquesta forma l'anonimat.
 - A partir de l'any 2006 es va començar a prendre consciència sobre la necessitat de fer servir mecanismes de protecció de la privacitat dels usuaris dins dels motors de cerca d'Internet de forma externa i independent als propis cercadors.
-

Introducció: Objectius

- Implementar l'esquema de protecció de la privacitat dels usuaris dels motors de cerca d'Internet proposat per Alexandre Viejo i Jordi Castellà-Roca en la seva publicació "*Using social networks to disort users' profiles generated by web search engines*".
 - Els usuaris del servei implementat han d'estar organitzats i connectats entre sí a través de les xarxes socials, i han de compartir entre ells la informació i els serveis sense dependència de cap node central o entitat tercera que supervisi la informació intercanviada.
 - Les peticions de cerca dels usuaris han d'anar viatjant a través de la xarxa social seguint una sèrie d'algorismes de distribució, fins que algun d'ells envii la consulta directament al motor de cerca.
 - S'ha de garantir la correcta protecció del sistema en front d'usuaris il·legítims que pretenguin utilitzar l'anonimat que proporciona el servei per a realitzar consultes il·legals.
-

Introducció: Justificació

- L'esquema proposat per Alexandre Viejo i Jordi Castellà-Roca garanteix la privacitat dels usuaris dels motors de cerca.
 - Es fonamenta en dos principis bàsics:
 - La proliferació de la connexió a Internet de banda ampla en tots els ordinadors.
 - La introducció gradual dels usuaris en les xarxes socials.
 - Sistema independent d'entitats externes o espais de memòria compartida per a la distribució de les peticions de consulta.
 - Els algorismes de distribució de la proposta eviten l'ús de consultes aleatòries o falses per a aconseguir l'emascarament de les identitats.
 - No són necessàries infraestructures complexes i poc usables.
 - No és necessària col·laboració per part dels motors de cerca.
-

Introducció: Planificació

- El desenvolupament del projecte es va dividir en una sèrie de tasques. Al següent diagrama de Gantt es pot apreciar la planificació del projecte.



Descripció de l'esquema

- Model del sistema
 - Protocol d'enviament de consultes anònimes
 - Funció Ψ : Estimació del nivell d'exposició del perfil dels usuaris
 - Funció Υ : Avaluació del nivell d'egoisme dels usuaris
 - Anonimat dels usuaris
 - Mecanisme de responsabilitat
 - Adversaris del sistema
-

Descripció de l'esquema

- **Model del sistema**

- **Usuaris**: Individus que envien consultes cap al motor de cerca d'Internet. Organitzats en xarxes socials.
 - **Motor de cerca**: Servidor al qual els usuaris envien les seves cerques.
 - Un usuari U_i genera una consulta q_i per a ser enviada cap el motor de cerca d'Internet. Amb aquesta consulta l'usuari U_i pot fer dues coses:
 - Enviar la consulta q_i directament cap al motor de cerca.
 - Enviar la consulta q_i cap a un dels seus contactes de la xarxa social. Per exemple U_j
 - Un usuari U_j que rep una consulta q_i de l'usuari U_i pot fer amb ella dues coses:
 - Enviar la consulta q_i directament cap al motor de cerca.
 - Enviar la consulta q_i cap a un dels seus contactes de la xarxa social. Per exemple U_k
-

Descripció de l'esquema

- **Protocol d'enviament de consultes anònimes**

- Un usuari U amb una llista de contactes de la xarxa social $\{N_1, \dots, N_k\}$ pot delegar l'enviament d'una consulta q en un d'ells (o en ell mateix) enlloc d'enviar-la directament al motor de cerca.
 - **Funció Ψ :** Estimació del nivell d'exposició del perfil dels usuaris
 - Retorna com a resultat a quin usuari de la llista d'usuaris $\{U, N_1, \dots, N_k\}$ li ha de ser enviada la consulta q per que aquesta sigui enviada al motor de cerca. Per exemple: N_j
 - Si l'usuari triat per Ψ és el mateix U , llavors U envia la consulta q directament al motor de cerca.
 - **Funció Υ :** Avaluació del nivell d'egoisme dels usuaris
 - Determina si l'usuari N_j que ha rebut la petició de consulta q enviada per l'usuari U ha d'acceptar-la o no.
 - Si N_j accepta la petició: N_j inicia el protocol amb els seus contactes.
 - Si N_j rebutja la petició: U inicia el protocol amb la resta dels seus contactes.
-

Descripció de l'esquema

- **Anonimat dels usuaris**

- El sistema garanteix l'anonimat entre usuaris que no estan directament relacionats entre sí en la xarxa social.
 - Aquest anonimat pot animar usuaris deshonestos a enviar consultes il·legals al motor de cerca fent ús del sistema.
 - **Mecanisme de responsabilitat**: El sistema fa ús de les signatures electròniques avançades i la *PKI* per a protegir els usuaris honestos.
 - Cada petició de consulta q que un usuari U_1 envia a un usuari U_2 ha d'anar acompanyada d'un certificat de transacció signat amb el certificat electrònic de U_1 : $\{q \parallel U_1 \parallel U_2 \parallel timeStamp\}_{SKU_1}$
 - L'usuari U_2 que rep la petició de consulta q pot demostrar davant una autoritat legal que la consulta q ha estat enviada per l'usuari U_1 presentant el certificat de transacció signat per U_1 .
-

Descripció de l'esquema

- **Adversaris del sistema**


- **Motor de cerca**: El protocol d'enviament de consultes entre usuaris de la xarxa social evita que el motor de cerca pugui saber qui ha originat una consulta i per tant crear perfils dels usuaris.
 - **Usuaris que creen perfils d'altres usuaris**: L'anonimat existent entre usuaris que no estan connectats a través de la xarxa social no permet que usuaris deshonestos creïn perfils de la resta d'usuaris a partir de les seves consultes.
 - **Usuaris egoistes**: Els usuaris que mai accepten peticions d'altres usuaris són penalitzats per els algorismes de distribució del protocol d'enviament de consultes anònimes quedant aïllats i havent de enviar les seves pròpies consultes al motor de cerca.
 - **Sybil attack**: Un usuari que crea usuaris falsos a la xarxa social no podrà entrar en el sistema a menys que la resta d'usuaris acceptin voluntàriament establir connexions amb ell.
 - **Usuaris que envien consultes il·legals**: El mecanisme de responsabilitat del sistema evita que els usuaris enviïn consultes il·legals des del seu anonimat perquè aquestes han d'anar signades electrònicament.
-

Disseny de la implementació

- Esquema general
 - Casos d'ús
 - Infraestructura tecnològica
 - Xarxa social
 - Perfil d'usuari
 - Protocol d'enviament de consultes anònimes
 - Mecanisme de responsabilitat
 - Comunicació entre usuaris
-

Disseny de la implementació

- Esquema general



Disseny de la implementació

- **Casos d'ús**

- **Actors:**

- Administrador de la xarxa social
- Usuari del *Servei de Consultes Anònimes*

- **Casos d'us:**

- Inicialitzar xarxa social: L'administrador de la xarxa social ha d'inicialitzar la xarxa social que el sistema farà servir posteriorment, amb les dades dels usuaris i les relacions existents amb aquests.
 - Arrencar el *Servei de Consultes Anònimes*: L'usuari del *Servei de Consultes Anònimes* que vulgui realitzar consultes anònimes contra el motor de cerca, en primer lloc haurà de posar en marxa el servei.
 - Enviar consulta al *Servei de Consultes Anònimes*: Una vegada el *Servei de Consultes Anònimes* ja està en marxa, l'usuari podrà fer consultes contra el servei enlloc de fer-les directament contra el motor de cerca.
-

Disseny de la implementació


- Infraestructura tecnològica

- Llenguatge de programació: *Java*
 - Llibreries addicionals
 - *Bouncy Castle Crypto API* (Operacions criptogràfiques)
 - *Apache Commons IO* (Operacions entrada/sortida fitxers)
 - *SLF4J i LOG4J* (Manteniment de “logs” del sistema)
 - *Oracle JDBC* (Connexió a base de dades)
 - Entorn de desenvolupament: *Eclipse Indigo IDE*
 - Eina de funcionalitats criptogràfiques: *OpenSSL*
 - Sistema de base de dades: *Oracle XE Universal*
-

Disseny de la implementació

• Xarxa social

- Sistema de vinculació entre persones connectades entre sí per diferents tipus de relacions.
- Per a implementar l'esquema s'ha desenvolupat una simulació de xarxa social de la forma següent.




■ Implementació:

- ❑ Topologia de *xarxa en malla*. Cada node pot estar connectat amb la resta de nodes de la xarxa directament o indirecta.
- ❑ Usuaris de la xarxa social identificats per la parella *<adreça IP:port>*
- ❑ Cada usuari de la xarxa social té associat un certificat de clau pública.
- ❑ Configuració de la xarxa a través d'un document *XML* que conté la informació dels usuaris i les relacions existents entre ells.
- ❑ Dades dels usuaris emmagatzemades en una base de dades *Oracle Express* a la qual es connecta cada usuari per accedir a les seves dades.
- ❑ Els usuaris es descarreguen de la xarxa social la informació del seu perfil d'usuari i dels perfils dels seus contactes directes.

Disseny de la implementació

• Perfil d'usuari

- Al iniciar el *Servei de Consultes Anònimes*, els usuaris descarreguen les dades dels seus contactes de la xarxa social:
 - ❑ Adreça IP i port
 - ❑ Certificats de clau publica
- Aquestes dades i les seves pròpies es carreguen a memòria per a permetre l'accés de forma ràpida al servei.
 - ❑ Adreça IP i port
 - ❑ Dades dels seus contactes
 - ❑ *Keystore* i dades d'accés al certificat i a la clau privada.
- Les dades descarregades de la xarxa social es guarden a la màquina de l'usuari en un document *XML* que s'anirà actualitzant.
 - ❑ logs/profile.xml



```
<?xml version="1.0" encoding="UTF-8" standalone="no"?>
<User id="192.168.1.33:5552" p="1.0" t="0" tau="0">
  <Certificate>MIIDqzCCAxSgA...</Certificate>
  <ContactList>
    <User id="192.168.1.33:5551" p="1.0" t="0" tau="0">
      <Certificate>MIIDqzCCAxSgA...</Certificate>
    </User>
    <User id="192.168.1.33:5553" p="1.0" t="0" tau="0">
      <Certificate>MIIDqzCCAxSgA...</Certificate>
    </User>
    <User id="192.168.1.33:5552" p="1.0" t="0" tau="0">
      <Certificate>MIIDqzCCAxSgA...</Certificate>
    </User>
    <User id="192.168.1.33:5554" p="1.0" t="0" tau="0">
      <Certificate>MIIDqzCCAxSgA...</Certificate>
    </User>
  </ContactList>
</User>
```

Disseny de la implementació

- Protocol de consultes anònimes

- Cada node del document `profile.xml` descarregat per l'usuari correspon a un contacte. Aquest té associats uns atributs:
 - **p**: Probabilitat que té l'usuari d'acceptar consultes procedents del contacte corresponent al node.
 - **t**: Nombre de consultes que el contacte corresponent al node ha intentat delegar en l'usuari.
 - **tau**: Nombre de consultes que el contacte corresponent al node ha acceptat de l'usuari.
 - Els valors d'aquests atributs seran carregats a memòria i utilitzats pels algorismes de distribució de consultes del servei:
 - **Funció Ψ** : Estimació del nivell d'exposició del perfil dels usuaris.
 - **Funció Υ** : Avaluació del nivell d'egoisme dels usuaris.
 - Els valors d'aquests atributs s'aniran actualitzant i emmagatzemant sobre el propi fitxer `profile.xml`
-

Disseny de la implementació

- **Mecanisme de responsabilitat**

- S'ha fet servir *OpenSSL* per a generar els elements de la *PKI*: Certificats, claus i “*keystores*” de la Autoritat de Certificació i usuaris.
 - Cada usuari disposa d'un “*keystore*” de tipus *PKCS#12* que es carrega a memòria durant la inicialització del *Servei de Consultes Anònimes*.
 - El certificat de transacció $\{q \parallel U_1 \parallel U_2 \parallel timeStamp\}$ s'implementa com un objecte *Java* serialitzat i codificat en *Base 64*.
 - Les signatures del certificat de transacció generades són de tipus *CMS* “*attached*”. Si és vàlida es comprova que les dades del certificat de transacció contingudes dins la pròpia signatura són vàlides.
 - **Usuari envia petició a un contacte**: Genera un certificat de transacció i el signa amb la clau emmagatzemada al “*keystore*”.
 - **Usuari rep petició d'un contacte**: Comprova que va acompanyada del certificat de transacció signat i valida la signatura amb el certificat de clau pública del contacte descarregat de la xarxa social.
-

Disseny de la implementació

- **Comunicació entre usuaris**

- Tecnologia de comunicació: *RMI (Remote Method Invocation)*
 - Els sistemes dels usuaris fan de client i de servidor remot.
 - **Client**: Envia peticions de consulta al propi servei instal·lat a la màquina local de l'usuari i espera resposta.
 - **Servei**: Rep les peticions de consulta dels usuaris (del propi usuari o dels contactes directes) i s'inicia el protocol de consultes anònimes i el mecanisme de responsabilitat fins obtenir resposta.
 - Al iniciar el *Servei de Consultes Anònimes*, els serveis remots dels usuaris es publiquen amb la adreça *IP* i el port de connexió especificats, quedant accessibles per a la resta d'usuaris.
 - Els serveis dels usuaris localitzen els serveis dels seus contactes a través de les seves adreces *IP* i els seus ports descarregats de la xarxa social amb les dades del seu perfil.
-

Implementació

- Amb la compilació del codi del projecte mitjançant *Ant* s'obté el fitxer *ZIP* `anonymous-queries-1.0.zip` que conté:
 - `lib`: Directori amb les llibreries utilitzades per el *Servei de Consultes Anònimes* i la llibreria que conté la compilació del propi servei.
 - Comandes:
 - `StartSocialNetwork`: Comanda d'inicialització de la xarxa social.
 - `StartAnonymousQueriesService`: Comanda d'inicialització del *Servei de Consultes Anònimes*.
 - `StartAnonymousQueriesClient`: Comanda d'enviament de peticions de consulta al servei.
 - Aquests comandes permeten executar els casos d'ús comentats amb anterioritat.
 - Cada comanda rep una sèrie de paràmetres com els fitxer de propietats de connexió a la base de dades de la xarxa social, el fitxer de propietats d'accés al “*keystore*” de l'usuari, el port de connexió, etc.
 - Tota la informació sobre el transcurs de la execució del *Servei de Consultes Anònimes*, consultes i certificats de transacció rebuts, etc. quedarà enregistrada als “*logs*” de la aplicació.
-

Marc d'avaluació

■ Objectius assolits:

- Analitzar en profunditat el problema de la conservació de la privacitat dels usuaris dins dels cercadors d'Internet.
- Proporcionar una solució basada en la proposta d'Alexandre Viejo i Jordi Castellà-Roca en la seva publicació "*Using social networks to disort users' profiles generated by web search engines*".
- Distribució de les consultes entre els usuaris de la xarxa sense necessitat de disposar de cap entitat tercera encarregada de supervisar ni distribuir la informació intercanviada entre els usuaris.
- Garantir la correcta protecció del sistema en front a usuaris il·legítics o egoistes que pretenguin fer-lo servir.

■ Treballs futurs:

- Testejar la solució amb usuaris distribuïts per la xarxa.
 - Integració de la solució amb les xarxes socials existents actualment.
 - Integració de la solució amb els navegadors i sistemes dels clients.
 - Integració de la solució amb *PKI* reals.
 - Ampliació del mecanisme de responsabilitat (*OCSF*, *Smart cards*...)
-

Resultats

- **Privadesa**: Els algorismes de distribució implementats aconseguixen que totes les consultes que els usuaris fan al motor de cerca quedin distribuïdes entre els seus contactes de la xarxa social, i per tant, el motor de cerca no pot saber quin usuari ha fet cada consulta i en conseqüència no pot construir el seu perfil. Quan la xarxa social creix en nombre d'usuaris i el nombre de contactes de cada usuari incrementa, el grau de privadesa també creix perquè, al haver-hi més usuaris entre els quals triar, les peticions queden més repartides entre tots ells i per tant, la seva identitat queda menys exposada.
 - **Usabilitat**: Per parlar de usabilitat en termes de temps de resposta caldria executar el servei en diferents màquines distribuïdes per la xarxa. És un dels primers treballs futurs que caldria considerar.
 - **Qualitat**: La resposta que el motor de cerca (en aquest cas *Google*) retorna al *Servei de Consultes Anònimes* quan aquest envia la consulta és gairebé la mateixa que la que retorna el motor de cerca directament, amb algunes petites diferències d'estil com són la absència de logos i d'alguns elements visuals. L'estil minimalista i amb escassos elements gràfics de *Google* ajuda molt en aquest aspecte.
-

Conclusions

- Amb l'ús del protocol *RMI* fent que els usuaris tant facin les tasques de client invocador del servei com de servidor remot, es va fer possible la correcta localització dels usuaris a través de la xarxa per part de la resta d'usuaris sense necessitat de disposar de cap entitat tercera.
 - L'ús del format de signatura electrònica *CMS "attached"* per a la generació dels certificats de transacció signats va aportar complexitat al desenvolupament però va facilitar el transport de la informació en les transaccions entre usuaris i va estandarditzar la solució.
 - Els requeriments d'emmagatzemament en que cada usuari del sistema ha de guardar els certificats de clau pública dels seus contactes i totes les consultes i certificats de transacció rebts van quedar coberts amb l'ús dels "*logs*" i del perfil d'usuari en format *XML* amb la informació de tots els contactes descarregat de la xarxa social.
 - Encara quedaria treball per fer per a poder proporcionar una solució perfectament integrada amb els sistemes operatius i els navegadors dels usuaris, i amb les xarxes socials reals existents avui en dia.
-