

Relevanța conținutului web și a comportamentului utilizatorilor în analiza traficului

Student doctorand: Diana - Florina HALIȚĂ
Coordonator științific: Prof. Dr. Florian Mircea BOIAN
Universitatea "Babeș-Bolyai" Cluj-Napoca
Proiect de cercetare

10 Iunie 2015



CUPRINS

1 Impactul similarității web asupra traficului

- MIGRAREA UNUI SITE WEB
- SIMILARITATE ȘI BOUNCERATE
- SCRAPER SITE

2 Interpretarea logurilor unei platforme de e-learning folosind FCA

- ANALIZA FORMALĂ CONCEPTUALĂ
- WEB USAGE MINING
- INTERPRETAREA REZULTATELOR FOLOSIND CIRCOS



Migrarea transparentă a unui site web între două sisteme de management de conținut

DE CE?

De ce să alegem un CMS?

- Întreținerea facilă - web;
 - Independența conținutului de prezentare;
 - Update-uri periodice de securitate;
 - Roluri multiple pentru utilizatori;


De ce este necesară migrarea?

- CMS-ul vechi este considerat învechit;
 - CMS open source;
 - Scalabilitatea CMS-ului nou;
 - Fructificarea noilor tehnologii web: CSS3, Ajax, HTML5.



PROVOCĂRI

- expunerea conținutului site-ului web la un URL nou
 - creșterea numărului de vizitatori care sunt induși în eroare
 - pierderea diverselor beneficii câștigate în timp



SOLUȚII

Soluții posibile:

- migrarea automată sau manuală;
 - estimarea timpului necesar migrării;
 - evaluarea procesului de migrare.

Soluții propuse de alții:

- plugin-uri care țin cont de comportamentul utilizatorilor în timp.

Soluția propusă:

- potrivirea perechilor de URL-uri;
 - AVANTAJ:
algoritmul se utilizează înaintea lansării site-ului.



REZULTATE




Figure: Batch processing

REZULTATE




Figure: Vechiul site: numărul de pagini accesate de către un referrer extern și numărul de pagini care au generat eroarea 404 și au fost accesate de către un referrer extern




Figure: Noul site: numărul de pagini accesate de către un referrer extern și numărul de pagini care au generat eroarea 404 și au fost accesate de către un referrer extern



REZULTATE




Figure: Vechiul site: procentul paginilor ce au generat eroare 404 și au fost accesate de către un referrer extern




Figure: Noul site: procentul paginilor ce au generat eroare 404 și au fost accesate de către un referrer extern

REZULTATE




Figure: Noul site: adaptarea motoarelor de căutare la noua structură a site-ului




Figure: Noul site: majoritatea erorilor 404 sunt generate de către utilizatorii care vin de la referrerii 3rd party

REZULTATE




Figure: Noul site: procentul paginilor ce generează eroarea 404 și procentul paginilor ce generează eroarea 404 și vin de la motoarele de căutare sau de la referrerii 3rd party




Figure: Procentul paginilor ce generează eroarea 404 având un referrer extern, odată ce a fost activat layer-ul suport propus



Analizarea legăturii dintre similaritatea documentelor web și a ratei de respingere generate de link-urile dintre aceste documente



DE CE?

Link-urile sunt folosite abuziv:

Scop:

- creșterea page rank-ului domeniului destinație;

Rezultat:

- utilizatorului nu îi este prezentată o informație de care să fie interesat;

Locație:

- sunt localizate fie sitewide, fie în cadrul conținutului absolut.



SOLUȚII

Tehnici de detectare a link-urilor abuzive:

- analiza conținutului
- analiza link-urilor
- analiza comportamentului utilizatorilor
- metode de clasificare automată, supervizată sau nesupervizată

Acuratețe:

- 80% din paginile care contin link-uri abuzive sunt detectate

Recomandare:

- combinarea tehnicielor ⇒ crește procentul de pagini abuzive detectate



REZULTATE




Figure: Similaritate ideală

- similaritate mare \Rightarrow rata de respingere mică
- similaritate mică \Rightarrow rata de respingere mare
- cea mai bună funcție de similaritate:
condiții: suma

$$\sum \frac{|x_i + y_i - 100|}{\sqrt{2}}$$

este minimă



REZULTATE




Figure: Similaritatea Cosinus




Figure: Similaritatea Jaccard

REZULTATE




Figure: Similaritatea Sorensen




Figure: Similaritatea Jaro Winkler

REZULTATE

Funcție de similaritate	Metodă	Valoarea sumei
Cosinus	conținut absolut	1804.476000579978
Jaccard	conținut absolut	1414.03085464388
Sorensen	conținut absolut	1769.3699189543242
Jaro-Winkler	conținut absolut	1528.5359097516346

Table: Suma distanțelor de la toate punctele de pe grafic la dreapta de ecuație $y = x - 100$



Măsurarea și vizualizarea nivelului de scrapping al unui site web



DE CE?

Probleme:

Prezența în SERP a unor site-uri care:

- direcționează greșit utilizatorii;
- direcționează utilizatorii spre un scraper site.

Consecințe:

- scăderea performanței motoarelor de căutare;
- nemulțumirea utilizatorilor referitoare la informația găsită



SOLUȚII

Identificarea scraper site-urilor:

- algoritmi automați;
- pe baza feedback-ului utilizatorilor - programe de învățare automată;
- pe baza similarității dintre conținutul aflat la pagina care face parte dintr-un scraper site și pagina sursă de la care a fost preluat conținutul.



REZULTATE




Figure: Non-Scraper site:
Similaritatea Cosinus - $\epsilon = 0.05$




Figure: Scraper site:
Similaritatea Cosinus - $\epsilon = 0.05$

CONCLUZII

Migrarea unui site web

- ponderarea proprietăților conținutului prezentat la un anumit URL;
- redirecționarea vizitatorului spre o pagină similară cu cea a referrer-ului.

Similaritate și bouncerate

- analiza similarității conținuturilor
⇒ (referrer, ∀ link intern);
- funcții de similaritate semantică;
- ponderarea funcțiilor de similaritate;
- ponderarea unor proprietăți specifice ale conținutului.



Analiza Formală Conceptuală



FCA

Definitie

Un context formal este un triplet (G, M, I) , unde:

- G reprezintă mulțimea obiectelor;
 - M reprezintă mulțimea atributelor;
 - $I \subset G \times M$ reprezintă o relație binară între mulțimea obiectelor și mulțimea atributelor, numită relație de incidență

Observație

gIm se citește obiectul *g* care are atributul *m*.



FCA

Definiție

Operatorul de derivare în FCA este o conexiune Galois între mulțimile G și M :

- $A' = \{m \in M | \forall g \in A, gIm\}, A \subseteq G;$
- $B' = \{g \in G | \forall m \in B, gIm\}, B \subseteq M.$



3FCA

Definiție

Un *context formal triadic* este un cvadruplu (K_1, K_2, K_3, Y) , unde:

- K_1 reprezintă mulțimea obiectelor;
- K_2 reprezintă mulțimea atributelor;
- K_3 reprezintă mulțimea condițiilor;
- Y este o relație ternară, $Y \subseteq K_1 \times K_2 \times K_3$.

Observație

(g,m,b) se citește *obiectul g are atributul m sub condiția b.*



3FCA

Definiție

Un **triconcept** al unui tricontext (K_1, K_2, K_3, Y) este un triplet maximal (A_1, A_2, A_3) cu $A_i \subseteq K_i$.

Observație

Pentru un triconcept (A_1, A_2, A_3) :

- A_1 se numește **extent**-ul triconcept-ului;
- A_2 se numește **intent**-ul triconcept-ului;
- A_3 se numește **modus**-ul triconcept-ului.



Web Usage Mining



WEB USAGE MINING

- tehnicele din Data Mining precum și cele din Statistică au fost utilizate pentru a extrage informații utile din log-urile web;
- tipologia site-urilor:
 - site-uri de e-commerce - **SCOP**: - vânzarea de produse;
 - site-uri de e-learning - **SCOP**: - oferirea de informații.
- o vizită pe un site educațional nu se aplica euristicilor utilizate de majoritatea instrumentelor de analiză.



REZULTATE

- **platforma de e-learning:** PULSE;
- **perioada de colectare a datelor:** Februarie - Iulie 2013;
- **ce investigăm:** tipare de comportament al utilizatorilor care folosesc PULSE;
- **date folosite:** clasele URL-urilor accesate, clase de referrer, timestamp-urile accesărilor username-ul studenților;
- ELBA, TOSCANA & Toscana2TRIAS.



CLASELE URL-URILOR ACCESATE (AF_CLASS)

- URL-urile accesate au fost împărțite în **9 clase**.




Figure: Clasele URL-urilor accesate

CLASE DE REFERRERI (R_CLASS)

- URL-urilereferrer-ilor reprezintă paginile dinspre care utilizatorii vizitează o pagină dintr-un site;
- referrer-ii externi platformei PULSE nu au fost considerați în acest studiu.




Figure: Clase de referrer

WEB USAGE MINING FOLOSIND 3FCA

- Toscana2Trias permite selectarea datelor triadice pornind de la un set de scale preprocesate în ToscanaJ;
- Date de intrare pentru Trias:
 - atribute: perechea (R_CLASS - AF_CLASS);
 - conditii: timestamp;
 - obiecte: studenti.



Interpretarea rezultatelor obținute în 3FCA folosind CIRCOS



INTERPRETAREA REZULTATELOR OBȚINUTE ÎN 3FCA FOLOSIND CIRCOS

Observație

- XML-ul generat de TRIAS conține toate triconceptele derivate din tricontext;
- fiecare triconcept e definit de extent, intent și modus;
- datele de intrare pentru CIRCOS trebuie reprezentate într-un tabel bidimensional, $R \times C$.



INTERPRETAREA REZULTATELOR OBȚINUTE ÎN 3FCA FOLOSIND CIRCOS

Observație

- $(G, M, B, Y) \Leftrightarrow (G, (B, M), I)$, $(g, (b, m)) \in I \Leftrightarrow (g, m, b) \in Y$;
- $\forall (b, m) \Rightarrow$ numărul de elemente din extent este $(b, m)'$;
- $C =$ mulțimea care definește indicatorii de coloană, obținută prin proiectarea relației Y pe M ;
- $R =$ mulțimea care definește indicatorii de linie, obținută prin proiectarea relației Y pe B ;
- valorile numerice ale tabelului se calculează astfel:
 $\forall (c, r) \in C \times R$, numărul de elemente din extent $(c, r)'$ este calculat direct din XML-ul rezultat din Trias.



INTERPRETAREA REZULTATELOR OBȚINUTE ÎN 3FCA FOLOSIND CIRCOS




Figure: Grupa: "ar" - săptămână

REZULTATE

Test specification

- **durata:** un semestru;
- **date:** grupe de studenti;
- **triconcepte:**
 - **obiecte:** R_class;
 - **atribute:** AF_class;
 - **condiții:** timestamps;
- **comportament:**
 - relaxat;
 - intens;
 - normal.

Rezultatele obținute sunt publicate:

<http://www.cs.ubbcluj.ro/~fca/tests-2013/>



REZULTATE

■ comportamentul relaxat:

- apare în special în timpul vacanțelor;
- **observație:** număr redus de URL-uri accesate;
- **tipar:** HOME ⇒ LAB ⇒ LECTURE;
- **tipar:** HOME ⇒ LECTURE ⇒ HOME;



REZULTATE

■ comportamentul normal:

- apare în timpul semestrului, când nu sunt examene sau vacanțe;
- **observație:** aproape toate clasele de URL-uri accesate sunt vizitate;
- paginile din clasa LAB sunt cele mai vizitate.



REZULTATE

■ comportamentul intens:

- apare în special în perioadele cu examene;
- **observație:** număr mare de accesă;
- paginile din clasa LECTURE sunt cele mai vizitate;
- HOME reprezintă un liant între restul facilităților oferite de PULSE;



REZULTATE - GRUPA: "AR"



Figure: SO:
comportament relaxat




Figure: SO:
comportament normal




Figure: SO:
comportament intens

REZULTATE - GRUPA: "RI"




Figure: SO:
comportament relaxat




Figure: SO:
comportament normal




Figure: SO:
comportament intens

REZULTATE - GRUPA: "IE"




Figure: WDO:
comportament relaxat




Figure: WDO:
comportament normal




Figure: WDO:
comportament intens

REZULTATE - GRUPA: "EI"




Figure: WDO:
comportament relaxat




Figure: WDO:
comportament normal




Figure: WDO:
comportament intens

CONCLUZII

- ajustarea parametrilor în fișierele de configurare ale CIRCOS, precum și afișarea datelor într-un alt format decât cel circular.
- construirea unui algoritm bazat pe probabilități condiționale pentru a șterge conceptele cele mai puțin importante.
- utilizarea TCA pentru a evidenția din punct de vedere temporal comportamentul utilizatorilor, atât individual cât și pe grupuri.



Mulțumesc!

Q & A

