

① 12/3/09
בב

נושאים מתקדמים בלשון / תנ"ך

* השנה הדגש הוא מידע ברש

הנושאים:

* יקד - איך האנטיק לאבד { ואמשק אגהק הוחק בקורס
- ש'מושיג של הרש

* מניח תיפוש - אינדוקס, שאלתור, איסור מידע וכו'

* XML

הדגש המרכזי מקדישה זמן בקורסים שלה לתר-אוטיביציה
למסמךי זמה בעל יש לדון בתחום. אבל ואן זה די
ברור. אנחנו משמשים באנטיקס ס הנמ, ההשפעה
של האנטיקס קלינו היא עצומה. החומר מאוד חדש
ומה שמאוד יפה הוא שזה תחום שמאוד משפיע על חינו
אצל הוא גם מתבסס מאוד תפק א תומי תיאורטי שלמדנו
באוניברסיטה. חול מזה יש גם המון מקום למחקר ותרומה.

תרגומים:

* אין מתרגל ואין בודק. המרכז מעבירה את התרגום
* ברוב השפועות ינתן תרגיל ביר אשבוש.
התרגומים אופציונליים ול תרגילי למגישם מלכה הנקודה
בצין הסעי (נמוך יו). אפשר גם זהציה או-
הנכיון בכיגה וגם זה מלכה אומנו הנקודה.
סה"א פשה אצבור עד יושב בעצירה התרגומים.
לא כל מה שנמצא בקורס אופיון השקפים - הרבה פעמים יש
השקפים שאור-שתחור.

איך האַינטערנט עובד?

המסרה הראשונה היא להבין איך אינטרנט עובד ומה יכול
אנחנו יהיה לקרוא באינטרנט.

מה קורה בשלוחים? איך בדף web? מאחורי הדף
יש למשל קוד html. איך יש שני חלקים -
הידע שלו והטקסט שאנחנו רואים על המסך. אוב
שלוחים הטקסט אנחנו כותבים להגיד לכתובת,
אזא שזה רק שם. מה שבאחר כך זה כתובת IP.
כתובת זו אנחנו יכולים לקבל מה DNS. הוא מקליט
בין שמו טקסטואלי לכתובת IP.

הדפדפן רוצה לבקש את הדף מהשר. שרת web
הוא תוכנה שיודעת להתחבר משאבים אלה בשביל זה
צריך לדעת את ה- IP וה- port ששרת השל
מאזין. בדף יש שימוש ב- port 80, אבל לפעמים יש
הפניה למקום אחר. בדף המתנה מקופץ רק שהם
יודע מראש כמה IP-ים של DNS-ים. ה- DNS
מקבל שם של שרת ואחרי זה כתובת שלו. איך?
ה- DNS אחריהם בתוכו כמה מידע ואם הוא לא
מוצא את הכתובת הנחוצה הוא יכול לפנות ל- DNS
אחר וכן הלאה. בסוף הכתובת תוגדר למשתמש.
הדפדפן שוחח חבולה עם הפרטים הנחוצים. הפרוטוקול
של שליח התחבורה לקרא IP.

אחרי שקיבלנו את ה- IP של השרת שיצאנו צריך לשלוח
לנו בקשה למשאב. השליח מתקן את המשאב לחבולות
קטנות ושוחח אולי למשתמש. הפרוטוקול הזה לקרא TCP.
הפרוטוקול הזה בודק שהמשאב אכן הגיע למשתמש ואם לא
הוא שוחח שוב. החבולות מגיעות למשתמש עם מספרים

סיכוריים, המחשה מסד אורך לפי הסדר ומציג
מצפצפן.

משאב זה פיסר אינפונמציה שיופס זכור ע"י URL.
זה יורר זהיר קולר (סקס, תמונה ...) או דל דנאמי.
מה שאנחנו רואים מצפצפן הוא שילוב של כמה משאבים -
בקוד HTML של הדל יש תפניה למשאבים אחרים וסר
המצפצפן זריק זכקל אותם מושר במיוחד. זק הרבה
פעמים נשערה דל web אנחנו רואים או הטקסט
לפני התמונה.

האברה והמסיס של URL הנו

protocol:// domain / path

ה- URL יורר זהיר זה זוכן שמשפס עזשו זיך למצער
הזמור ולא להתחלתו. אפס זהוסל פרמטרים שמשמשים
הזיך, המצדום דנאמי.

אז התורה הזלי היא

protocol:// domain | path # anchor ? parameters

זוד פוסים סכניים המצגת. וגם דוגמאות.

הערה:

* נשמים עוזן ה- URL אקרוים אז אורי המשאב כמו
למי הזיגן. זו פשוט קודר כניס, שונה אהל זה אורי המשאב.
* נשמקלים URL עם פרמטרים אורי (קב) משהו שונה ואורי
לא - זה תלוי משג.

אנקום ימסיים -

אפס ה- HTML לא זכקל אז הכתובת המשאב אלא רק
path ואז המצפצפן אנוי שלם היחס למקום שמה ערשו
נמצא בו. מה שמה עושה זה להתחיל אמה שאחרי
ה- slash האחרון ה- path.

הערות:

* ה-URL מזהה באופן יחיד משאב. בהינתן URL אפשר
להגיע רק למשאב אחד.

* לאתומטאב יחידים עבריות כמו URL-ים שונים. למשל

www.notes-heaven.com

www.notes-heaven.com/index.html

זה נראה כמו עניין ממש פשוט אבל זה יותר איזורים מני העיון -
למנוע חיפוש. למשל Google אומרים שכל היתאחשוב אם
הרבה דפים אחרים מזהים אותו. אם ה-URL ים שונים
זה פותר בחישוב נזה.

דפים דינאמיים: עד ערשן הנחנו שהיה מקבל בקשה,
נימלז למחברת הקבצים ומחזיר את מה שצריך.

אם לא היינו דפים שמורים במערכת הקבצים. למשל, תוצאות
חיפוש לא שמורים ושל - amazon באתרים לנו
hello dina

הם בוודאי לא שומרים מאוסן מיוחד דל אל משמאל.
יש מני סכנואלוג שנותן דף איזור דפים דינאמיים ברצ
השלג. יחידים הם זהו דפים דינאמיים ברצ הלקוח. זה
נשלח דפדפן, מסמל אשורת לא. למשל, מדיקת תקינות
של קוד זה משלח להדפדפן יחיד אשורת ולא צריך לתקן
הם השגת ברצ זה. או למשל מני תפריטים שנפתחים
וכן זה ברצ הלקוח.

כמוכן, אפשר גם לכתוב קוד שפוג דינאמי בשני הדפים.

דוגמה: Counter שמספר נכנסים אל web הוא אומטאבר ברצ
השגת - רק הוא יודע כמה אנשים נכנסו.

- תוצאות חיפוש מחשבויר ברצ של השגת.

- באופן כללי אם צריך לשלח אינשאו אינצ במסד נתונים זה חייב
זהו ברצ השגת.

3

היתרון בחיפוש דברים בצד האתר הוא שזה מוריד טראפ מהשרת אבל החיסרון הוא שיש לקחת לא מאפשרים לממש זיהוי אדום javascript (משיקור security) ואם בעצם אי אפשר לתת זהם לפני.

אם השתתף מתקדם עם המחשב שלי? הפונקציה (קראו http). הדפדפן יוצר אשליה בקשה http והשלח web מאגין לבקשה ויוצר אשליה. איתנו (דבר) http 1.0.

השלבים הבאים הם:

- האקט פותח ערוץ תקשורת
- האקט שולח בקשה
- השרת שמאגין מקבל את הבקשה
- השרת שולח תשובה
- הסתף נסגר

הפונקציה היא stateless - כלומר אחרת לבקשה נענית הוא שונה לכל הייתה תקשורת. אם, אם איתנו חוזרים איזשהי דבר לזכור מידע אי אפשר להשתמש בפונקציה ולכן למצוא דבר תכנותי אחר. למשל - cookies.

הפונקציה עם דוגמאות נמצא במצגת. אבל כדאי יש לי איני הקדמות - headers ואם גורן אופציונלי. למשל, יתר אזור בבקשה רשם יחס הדפדפן. זה אם כי אולי יש יחסא שגור לאתרי מאוד מהתאם לדפדפן, אם כמובן להם היום ה- URL הוא לאתרי צייתי חד-צדדי למשל. עוד דוגמאות של headers במצגת.

אפשר להפחית פעולות שגור (התחביר) get, put, delete (וכו'). כמובן תשתית הדף ואי אפשר אני לעזור לי מיני דברים מורכבים.

וזה אלהיך שנקראת רשומה או השרה של ה-headers באופן צפוני.

- cookies
- referer - רמז אם המפנה מקבל חזר על הדפניה
אחי נורה ושלג אגו.
- user-agent - זכרון - אג היתם השונה לצפופנים שונים

ארגומה של השפה יש אמה דומה - הקדמה ואז המשלב.
למשל יש header שאומי או אורק המשאב שזה תשובה.
שפצפצן "צד שמך קיבלנו אתה" ונתוב גם סוג המשלב
נדי שפצפצן "צד אורק אהצם אגו."
מאצגיש רשימה של הקצים שמותרים "השפה".

תופעה מעניינת: רשומים זכרון -

http://www.cs.huji.ac.il/~jeff

הצפצפן משנה את הכתובת -

http://www.cs.huji.ac.il/~jeff/

מה שקורה הוא שהשפה web אורק לצפצפן להכתובת
של האור השתנתה ואז הצפצפן אקור שום זמקא
אז הנתובת החדשה זמ ה- slash
זה טוב באלף הונקים היתסיים. אור יש אגל אינקים
'חסם בצל' וכתובת הייתה שאתה בלי ה- slash אז
הם זכרון עובדים!

אפי מו שאמתי עד ערשו זכרון אשאר הצפצפן שום כתובת
זשפה. זה כמובן לא הינו כי אפצמים נכנסים אלף פעמים
לאלו מקומ. לאלף google יש סאקטן ותמוד. חבל
ב צקור אהביא אורו אהצם. אז בשלב אהסוק
התעבורה באינטרנט עושים caching. אפשר לעשות
אגזה מקומית של המחשב או באמצעות proxy לעולם
caching בתוכו. כאומן, יש היררכיה של proxy-ים.

4

היתרונות של caching הם ברורים. הבזיה העיקרית היא
שאנחנו עוזרים לקדם מצב לא עובד.
יש עוד שני יתרונות אחרים - proxy - זמנים אישיים אצלם
מיומנים, אלקה אחי עובדים, אלהן אפן ויוחסים.

הוכנה proxy המיומנים מאצנה ואיזה port ואז באמצע
אונסופר מקבלת בקשה ועונה לה. במצב יש שני דוגמאות
למיומנים בשווייץ - java.

עזרים:

זה איצטו מנצח שמעשה אלה ולקוח אומר על עתה בקשה
ארוך - משנה משותף שנהלנו כמו בקשה לאורך זמן.
נשאננו שולחים בקשה השני יחד אלקה מאתנו לעצבן עזרים
המתלה. העזרים שמר אצטנו המתלה במצב הקבצים.
עזרים היא למעשה אונסר משתנים עם ערכים. לא אתר יש עזרים
משלו, רפי המידע העליוני. ואז נשאננו פונים לאתר שוב
אנחנו שולחים לו את ערכי העזרים ורק נוצר בקשה ארוכה
סוף.

הערה:

* תשובה יחד אלה כמה עזרים -

* עזרים עם אתר שם צורם - עזרים קצרים

אחת ש- http הוא stateless, אבל לא אגיש אתם
שצרכים צרכים. למשל, סקנר - amazon. הרעיון הוא
שהשירות והלקוח שולחים איזה פיס מידע יחודי לא אונסר -
session. אגלה אפסר עזרים בעזרת עזרים (אם יש גם
צרכים אחרים). העזרים האלה פזאג בקר מידע שסומרים או
העצבים. והמידע עצמו נשאר בדכ רק בצד השלם והעזרים אלה
אזשהי מפתח למידע הזה.

session יתן זרימה האת משני צדדי:

- סוגים אר הצדדים. במקרה ה' השלף לא יוצר לה-session
(אתר והוא ממשיך לשמור אצלו את המידע המשך כחן מסים
שקבע מראש (expiration) או ישלמים על logout
או משני צדדי.


האם עדיף זה בטוח? עדיף זה סתם סקט. הוא לא יוכל
לזהות ויחוס. אתי רשום של קוד צדוני. אבל זה לא יחולל אפוא.
עדיף לא יחולל לצידי את הדיסק כי הצדדים יש העברה על גוף
אחור העדיף.

אבל, עדיף יחולל לזהות איצד צד. עמל יתן זרימה שמספר
כדיס האשפאי שלני אופיע העדיף. הם אופן, עדיף יתנה לזה
רק איצד סודי שלנתן סיפקנו.

תניה עדיף: יש תקשורת בין שני הצדדים ויש packet sniffer
שינסה לזהות התקשורת. אז אם הוא וואה את תוכן העדיף
אתי הוא יתן זהתגור לז. אז אפשר להצפין...

הרעיון עדיף: יש שני אותיות שמכונה והנדון שזה העדיף
זהבם לא נכונים. עמל אם יש את ששזה עדיף לשלום
העדיף - אפשר לשלם את השלום...

עדיף צד שלישי - העדיף עדיף אתרים יתנים לעמוד האילו אתרים
אתרים הינו. עמל, האתרים עם פרסומות הפרסומות הצד
לא יושמו באותי שלף האתר אמא באיזה שלף אתר.
נששומים בק שלף אתמנה של הפרסומות נשלף אתה ה-referer.



5

השדה שממנו מגיע הפרסומה יותאם לשיתוף זיכרון
אמניקסני (א) אותה הפרסומה זיכרון כזה אתרים שונים
השדה של הפרסומה יותאם לזדה אה זה.
אז יש זיכרון בדפדפן עם מניח third-party cookies.

⑥ 19/03/09
DB

לפני שאתם ממציאים את הסינטיזר, הבסיסית של הסינטיזר, חובה
האנטיקט. נשאר לנו להשלים קטע קטן של אבטחה באינטרנט.
כוננו מכירים את הסינטיזר האנטיקט. שיהיה שמואל (נרצה
שכוננו יוכלו לראות הסינטיזר האנטיקט) (משקלתי צנעור חמוק)
נכבד שמואל וספשונו לנו תהליך תקשורת בעל יסודות. הבטיח
הוא שהתקביר את הסינטיזר ההצעה והצב בעצמה זוגית זה
לא מאבטח. לא מי שמסבין אתקשור יחול לראות את תוכן
הזוגית ולהתחבר אלנו. נרצה גם לראות שאין אחר לא
יתחבר אלנו. אבל זה יחול את הסינטיזר חרוץ את אישור
מתחזה אתנו הבנק שלנו.

הבטיח הבסיסית הניסו שאנחנו נודים להגביל את היכולת

לשם לאתרים מסוימים. יש כמה שאלות:

- איך נפיש אנחנו חוזים להגביל?

- מי יכול להשתמש בזה?

- איך לזהר את האנשים המותרים?

- האם צריך להצבין את הסינטיזר?

יש כמה אסטרטגיות

• *programmatic security* - אי שיתב את התוכנית

ממשל או הוליקה של האבטחה. התוכן של זה הוא שזה

מאוז גמיש - ממשל הוא אפשו. אבל הבטיח ההצעה היא

שצריך לזהר הרבה קוד ממשל.

• *declarative security* - אפשו להצהיר את המותר

לשם לאתרי זה. HTTP צואה ליישם את זה, זה מאוד

פשוט אבל מאוד מורכב, כי לא מה שיש לנו זה אוסף של

קטגוריות בין הדפים המשמשים המותרים שלהם.

אנחנו נצטרך קוד סוג זה של אבטחה.

מאחר (Realm) זה אוסף דפים עם שם. לא מאבטח

אזורים אולי גשמיים וסמאל. האופן שבו אזורים
אולי תלוי בשר. הרעיון הבסיסי הוא שרשמית
מבקש משאב אחד ממלכה הוא שזה שיש משאב וסימול
יש פרוטוקולים שונים לניהול של המלכה של שירותי משאב
והסימול. ה- <http> יש שני פרוטוקולים:

• Basic

- המשאב מבקש משאב

- השגר שולח גרסה של הבקשה (צחיה ושלך)
לאחר את המשאב

- הצדדים פותח תלון מבקש שיש משאב וסימול

אמלכה המבוקש (יכולה להיות רמה אמלכה)

- המשאב מבקש את הפרטים המבוקשים

- השגר מבקש את הניקיון ומחזיר תשובה בהתאם

מחלק ב session של התקשורת, הצדדים שומר

את המשאב והסימול של המלכה הבאה והוא שולח

אתם באופן אוטומטי צריך. זה חוסך לנו זמנה

וזמן. הצדדים הם יתלים זמנה את הסימול

למחז את (בקש ממנו).

פרוטוקול הזה מה שנשאל הוא `username:password`

וצה נשאל בהסס 64. זה לא הוצעה. זה נמש (שלה)

חשף 86 גרסיה. זאת התחלה העקרה של השיטה הזאת!

במשאבין מתקשורת או proxy בקר יותר זמנה את

הסימול.

• Digest - ואן האינדקס נשאל מולך וזה פתח את

התחלה העקרה של השיטה הקצרה.

רצין יש אמלכה וט' אלא שא הסימול בולמים אחי

שפדחים עליה פיוקציה ערמוז חז-כיווניה (כמו MD5).

הרעיון הוא שקל זמנה את הסימול אבל קלש זמנה אלה

מה עכשיו hash שלה.

7

השפד מקבל את שם המשתמש וה- hash ומחשב
שה- hash של הסיסמה ששומרה בצדו מתאים למה
שפדיו בפקטור.

אם, למשל לא נכתבו טון למצבה כי אפשר להאזין
ל- hash ולדון להתחזותו (Replay attack).
השפד להתחזות על זה למשל במשני שלקראו nonce.
גשר שמה לנו זיק אקראיחזם והמשתמש צריך
להחזיר את ה- hash של user:password:nonce
ובה מיונה את ה- replay. כי מי שחזרה להתחזות לנו
כבר יקבל מהשפד nonce שונה וטע זיק ה- hash
היפך לא יהיה תקף יותר.

אם אף אחד לא יוכל להתחזות ולקבל את המסומה
שלו אם לדון מילשו יוכל להתחזות אליו. השפד
למנוס אגדה גם הלקח שמה שמה משלו והשפד
צריך להתחזיר את ה- hash של user:password:nonce:
resource-content

רק אנתו גם ביטוחים שגוף אחד לא התחיל את התוק של הבל.
אנחנו לדון בהעיה כג אישומין לתקשורת יורו אוראו
אם המידע הסדי שלנו. השפד לה ציך אכלפין אמהינצ.
זה נעשה מאמצות פרוטוקול SSL (ר' קורס באמחה
אידע).

ערשו יש לנו הקנה הסיסמה על אק עובד וטאניסרס.
פ

Website Usability

זה לא חלק אינהרנטי מהחומר של הקורס אלא חלק
משינוי גוף אתר web וכתק אשירות עזומה נאמצקל
אק אדמור אחרים טובים.

הרבה מאוד אתרים אושקעים ומתוחכמים נחלים זהויר מאוד
 לרועים מחינת נוחות השימוש. בואי אתר גנוח לא בהכרח
 לא אושקע. למשל - www.brillpublications.com -
 אתר מאד אושקע אבל בעל לא נוח...
 עוד דוגמה היא השטים הנוראיים של HOT או של YES,
 שלא צבר של זה שום אנחנו רוצים להקליט גורנית סידא
 צניק לקרוא את כל חוכמה ההוואל כמה פעמים כדי להבין מה
 אשור. בעולם הפסי אנחנו קונים מוצר ורק אז מללים שמו
 לא נוח. אבל ב- web זה ממש קריטי: אף אחד בעל
 לא ישמש במור שלני אם האתר לא נוח לאבוד מה
 קורה שם.

מה זה שימושיות?

- learnability - כמה קל להבין איך משתמשים
- efficiency - כמה מזהר בצברים קורים
- memorability - כמה קל לזכור איך משתמשים
- errors - כמה שגיאות משתמשים עושים
- satisfaction - כמה נעים השימוש
- utility - האם האתר עק עושה מה שצריך

מחקר מראים ש-50% מכלל האתרים לא לוקחים בחשבון
 שיקלי שימוש בשמתכנים אלה. הנה עוד דוגמה לאתר
 מאוד מאוד גרוע - האתר הישן של 44 של בנק. הפעלה
 במצב.

איזה כלים צריך לקחת בה לבין כשמתכנים אתר?

- עיצוב הדפים - אומץ של הדפים יהיו הנויים לפי איזה
- template - זה עוזר למשתמש להבין איך לזכור צברים.
- כדאי שהקונטרסט יהיה טוב, שהתקף לא יהיה רועש, פונטים
- סלנצריים. בעל - סטנדרטי זה טוב - כולם רבו מכירים.

8

היגיון של הדף חשוב! אנשים לא אוהבים לרוץ למטה,
אבל לצד ימנה ושמאלה זו ממש קטסטרופה. אז צריך
לצאיהם שהאנר יתאים גם למסכים קטנים יותר.
ההמלצה היא לכתוב מעט - אנשים קוראים יותר מאשר
וגם הם שמים לב בדיוק רק לחלקים המודגשים. אלה המידע
החשוב צריך לשים למטה.

הכל הכי חשוב הוא התוכן - מה שמחזיר אנשים לאתר זה
התוכן המעניין!

• תצוגה עמוד הבית - זה הדבר הראשון שהמקרים חלים.
במצבים פיתוח של תיקון השטח של המסך לתכנים.
מה צריך להיות הלימוד הבית?

- אישורי משהל שמתאימה את זה שהאנר עושה.

- הכותרת (מה שמופיע בדפדפן למטה) צריכה
להיות בעצם משמעות.

- אחי אפילו חיפש

- להציג דברים חשובים

- splash screen זה לא טוב!

• אמנה האתר - ה navigation זה הדבר הכי חשוב.

זה צריך להיות נוח! מחקרים מראים שהרבה פעמים אנשים
מתאשים ויזמים מהאתר לפני שהם מוצאים את מה
שצריך. חשוב גם שכל שלב המעשה ידע איך לתמוך
למנוע הבטלה! ואם יש תצוגה של הלינקים לעברנו זה
עוזר למעשה להבין איפה הם נמצאים.

הלינקים צריך להיות ברור ואין שנתני מידע. צריכה

סימני מנהל (אולי אפילו אולג כ www.cuhza.com

או ה www.zaha-hadid.com.

• (היגיון) אנשים הם מוגבלים. יש אוסף בליט WAI:

- האתרים צריכים להיות נגישים לדפדפנים ישנים

- האתרים צריכים להיות נגישים לעיוורים

- האתרים צריכים להיות נגישים - mobile devices
ב מיני נטוורקס - מתקדמים כמו Flash או
JavaScript יכולים ליצור בעיות נגישות וצפופים
ישנים או למחשבים ("צים").
צניחת להיות אישיות עתידית אך העופנים - זה
חשוב לאוסוסה העצוקה.
חזית שהשמה של האתרים והז אינדקסיים עתידית.
רצי לחדוק את האתר שלי נגיש אפילו לאלו אך הוא
נראה זה צפופים שונים ויש גם מיני כלים
שאפשר להוסיף.

אז מינו אתר חדשים. צניק אדשור לו בדיקת!!!
צניק לדשור בדיקת השלם הראשונים, לפני הפרסום
זה אתר הפוסט.

סוגים שונים של בדיקת:

- גיבוע אדווים של מלכוכ
- למדוק שופש אדשור אימיה בסמן מסומ
- השוואה בין אדווים שונים עם תוכן צומה.

חיצות הבדיקת הוא פשוט - זקחים עקאות פוטנציאלים
ונותים להם משימות ואסתרים אך זה זומי עליהם
ומתקשים משה.

המצג יש ליוק עתיד שיש בו רשימה ממלכה של בדמרים
שכזאי לבדוק נשמונים אתר.

השית באופן סכנודי עושה logs של מה שקורה באתר
ואז אפשר לנתח אותם ולדדוק ב מיני דברים - זמק הבקדו
הצפופים, מסלול עינקים וזוד. זה מאפשר לנו לראות
מיצד על המשגשים באתר ואולי אפשר אז להתאים
להם את האתר בצורה טובה יותר.

9

מדוע בוג: לבחור אתר ידוע ואנחנו S ב ציון —
שימושיג באגז אזה ציון פתחונג .

נכנסים לחלק החצני יותר של הקרט

אנוצ' דיפואל

גופאג אנוצ' החיפוש כלל ו- google בפרט אמש
הרעידה אר העולם. אמש יש השערה שגאל לה
אנזיהים (וכנגד יש ציון אמ אנזי גאל זה השלן)
המסיה שלן גבה אהבין אמ לה קורה שגאל יוצה הט
ואמצרלני איצז א רק אהר .

אנחנו רוצים אנוצ' אנוצ' חיפוש. אהם הקשים ונציקריים שלנים
להתמוצז אהם ?

- כחור המיצז
- אדירוג העצרון של המיצז
- כימור הרלונטליוג , צירוג
- אנצוקס המיצז
- אציאג המיצז אלכחחילה
- התמוצזוג עם סוגים שונים של מציה
- הגנשם הרעים שמנסים להטור אר אנוצ' החיפוש (spam)
- כיסוי של המיצז

אנוצ' החפוש מתליק אשנו שוקראו index repository
שאנז מוצז על הצפים ואצ יש crawler ; indexer
שט כחאן רצים בקרז , אמששים איצז ומקניסים repository
ק/אפונטסוג נוספוג הן

- query processor - אנוצ' שאלותיה
- ranker - אצג גלגלוג

האתר הוא אינטרנטי (אתר) אגב הדברים שקורים
מאגו מן .

בשמיים הם (דבר) ה- index repository.

26/3/09
אסצ' (תנ"ס)

לפיכך הבא לא תהיה הרצאה רגילה ובלתיאפשרית. זה יהיה כאתר אינטרנט
ההרצאה של אנשים בגילאים שונים מתבקשים להקליט את
ההרצאה היא חומר אינטרנטי בקלות.

ף


היום נתחיל לדבר על storage - איך שומרים מידע? (תחיל)
במקרה הפשוט שיש לנו רק טקסט (לא גרפיקה וכו') אבל
חמש מאות הרבה ממני ונרצה לתלות איך לשמור אותם כדי
שלא יהיה זיכרון חיפוש יעיל.

קצת נראה כמה דוגמאות אפשריות לא טובים כדי לשמור
אינפואמציה לאה שכן חשבו.


נחזיר את המצב בצורה מדויקת: יש אוסף מסמכים ואוסף
אנשים ואנחנו רוצים למצוא את המסמכים שמכילים את
המילים. זה נראה לקחת בתלבוש? ברור שניתן לשלם
יהיה רמה שיותר מהר. מצד שני, בד"כ יש tradeoff בין
זיכרון לזמן. כאמור, צריך לקחת בתלבוש שכל שהשאלות
מסוגלות להיפתר על תלבוש זמן וזיכרון. למשל, אחרי
"hello world" זה יותר מסובק מלפני או המילים
בתוכן.

באופן, אנחנו נבצע הפשוטה של מסמכים ומילים.
כמה דוגמאות:

• hash table



• bit map



• אסצ' (תנ"ס)

• סתם קצת `grep` ומהיותי, שזאת אחפשים בהם, `grep` בזמן ששאלנו יעזרה ומהירה.

כדי להבין את ההצעה של שמעון כצאי להבין כמה זמן אוקה
זאת שלב זה של אנוני פזנא. במצגת יש פירוט
אם זה שבוטל הוא שמי אפשר לשמור את הנתונים
בבידוק הראשי כי הוא לא מאוחז בדוח ומצד שני הזמן
שלוקח לגשת לדיוסק הוא הרבה יותר גדול מפזנאוי ציבור
סאונתנו יתלים זה שמי. אכן נכזה שכמה ש'וגר נתונים
ישבו בבידוק הראשי.

פערון 1: אשטור אנהקב צים חנו שלם ומופל בהם ער
 בוי חנו prep . פה יש שני חלקים. מצד אחד,
 צינג אשטור אנהקב צים - אנהקביר אלה לבימון ואי
 אנהקב אלה.

נניח שיש לנו קובץ בגודל 10MB שיהיה במרכז דיסק.
seek time - $5ms = 5 \times 10^{-3} s$

seek time - $5ms = 5 \times 10^{-3} s$

transfer time - $2 \cdot 10^{-8} \cdot 10^7 = 0.25 \text{ s}$

זה רק בשביל זהביות אה הקבלה אציריין.
אם הקבלה לא תצטרף מציכרון והוא צי גדול והכל
הייתה יותר גרוע.

אז אמת'נא 1500 זה לא יחיד ואמת'נא 1500 זה תלוי.
באופן יקצי.

פערן 2: אשאר בארן (תנ"ך)

יש כמה דרכים להשלים את סדר התורה.

Doc ID | Doc

(LIKE insrt) . sql insert event sa

אמת'נה רע'יוני'ג זה זהה ל'ש'מי'ש ב-grep אלא פ'ק'א'י-

סה' ו' וגם גמחץ כזי צווא (גוניים) כאן בלע אלו רש"ה דא

מאופסאט לחיפושיה כאלה.

אופציה שניה היא לשמור דאטא

DocID	word
-------	------

ואופציה שלישית היא לשמור שתי טבלאות של דאטא:

word index
word | wid

appears
DocID | wid

מה עדיף? מבחינה זיכרון האופציה השלישית אבה יותר
כ שיהיה word ID תופס פחות מקום מהמילים עצמן
ומבחינה זמן, אחרי שמצאנו את ה- wid איתנו צריכים
לעשויה רק השאילת מספיקה וזה מהי יותר חלף מזה,
ניקטנו המקום משפחה את הצמנים של השאלה הנדונים
מהדיסק.

נשים לב שזה גם תוסף מקום לדאטא האופציה זאת הקבצים
כג ב מילה בסוף נשמרת רק פעם אחת והרי טבור לבחסמכים
עצמם המילים תוצרה כל עצמן.

מה לחבי חילום השאילת? אם מסבכים את השאילתא-
מוסיפים עוד מילה והעיקר אם מוסיפים מילה הצמן יתל
להצברה די מהר ואילו בקבצים זה די יעיל.

אסיכום, הפתרון של מסד נתונים מתנהג יותר טוב כשיש
הרבה מאות איצט כג את השפירות של הצירוף משפטים
יותר, אבל אם יש יחסית מעט איצט עדיף כבר לשמור את
הקבצים וזהו.

ואם צאר לפתרון היסודי יש חסרון/ג - אם יש מילה
שמפיעה בהרבה מאות מסמכים זה אומר ששומרים את
ה- wid שלה הרבה מאות פעמים וצריך לשלם להרבה
שורות. וכאובן יש אגהכעיה שזה לא תועף ביציוליו-
השאילתה עם הרבה מילים.

פתרון 3: Bitmaps

הפתרון הקודם הוא שפועל על בסיס מחשבוני הממלא בזיכרון מיליון יעילה.

אם, אם רוצים למצוא rain and parch and
על השורה המתאימה. מצאנו פשוט ויזיל.

אבל מה לגבי הביצוע? נניח שיש 500,000 מילים שונות

1 - 10,000,000 מסמכים, אבל אחרי זהם 1000 מילים.

אז זה - 5% מהמילה יש אחרות. אז זה בעצמו

אקלים מסוים!!! ב זה מסמך אחד או -

Repository Index

יש שני מבני נתונים:

- רקסיקון - אוסף של המילים המסמכים אבל מילה יש פונקטור

1 - inverted index שלה

- inverted index - אז מילה הרקסיקון יש רשימה של

פונקטור אז המופעים שלה המסמכים

נשמע מצאנו פשוט. אם רוצים למצוא מסמכים שיש בהם

שתי מילים צריך לחתוך את הרשימות. אבל,

The Devil is in the Details

הרקסיקון השם הזה נניח לאין שאלות מסובכות אבל

הם מתפשים פשוט מילה אחת. המילה היא למעשה

יחיד ואילו קטן - רק באותו נצטרך לדעת אתו לזיכרון הרשמי.

אם מילה נכזה לשמה את הפונקטור הרשימה שלה ואז אוק

הרשימה. זה נכון לשמש את מיני דברים (אם צריך) אבל

אכנה זה פשוט מאפשר לנו לדעת מילה צורה או קריאה

הרשימה.

אנחנו נניח ש - יש 1 מיליון אותיות

כל אותה באורך לכל היותר 20

אותה ממוצעת באורך 8

כל תו זה 1 byte

כתובת בזיכרון זה 4 byte

זמן ה frequency 4 byte

אופציה 1: לשמור את האקסטרקט של שאלה ~~ש~~ $20 \cdot 4 + 4 + 4$ שאלות אורך. אז כל שאלה תהיה באורך $20 \cdot 4 + 4 + 4 = 84$ ואם סכום זה $84 \cdot 1M = 84M$ זה בעצמי כי אותה ממוצעת היא באורך 8 ...

אופציה 2: אפשר לשמור את כל המילים ה-string אחת אחת ולשמור פונקציות לזמן ה-string כשה שמאל איפה כל אותה מתחילה. זה חוסך: $1M \cdot (8 + 4 + 4 + 4) = 20MB$ אם תסבין 8M


אופציה 3: יתרון זה'ל הרבה אותיות אם אלה תחילי (prefix) ואם תהא לשמור את זה פעמים. זה אפשר להשתמש במתנה שנקרא front Coding. מתנה ש תחילי ממוצעת משוערת היא באורך 3 נקב' $1M \cdot (5 + 4 + 4 + 1 + 4) = 18M$

הבעיה היא למתנה כזה אי אפשר לעשות חיפוש בינארי

אופציה 4: 3-in-4 front coding - כל בלוק של 4 אותיות
הכאשר (מתנה בשאלה ושלוש האחרות מקוצרות).
jezebel jeziel
jezer jezielah
jezerit jezoar
jezielah jezielah

שם יש String ארוך
 7 jezebel 1 r 2 itiah 6 jeziel 4 liah 3 oar rahiah

חול מהמילה הראשונה (שלוש האותיות) או התחילית
 המשותפת עם המילה הקודמת. (כל המילים פה) (אחרונה)
 מתבנים את אורך ה-suffix שמשנה. (מילה הראשונה)
 אורך ה-suffix הוא פשוט אורך המילה. וכן לכל ה
 מילים. ברור שזה יהיה עצמו. לא מספיק. שם יש גם



אם דושיה פה חופש? אפשר לעשות גרסה בינארי
 והחלוקים ומסחר שלחלקים כאלו קבוע - כל אחד 4 מילים -
 אונתני עדין (שגרים עם סיבוכיות) לוגית מאוד. הדפוס בגוף
 החלוקה פשוט כג. יש לנו את המידע הנדרש.
 כמה מקום זה תופס? (כל מילה שומרים מספר מופעים ותקרה
 שזה $(4+4) \cdot M$


זרוע מהמילים שומרים את המילה - $8 \cdot M \cdot \frac{1}{4}$
 לשאר המילים שומרים את ה-suffix באורכו הממוצע 5 -
 $5 \cdot M \cdot \frac{3}{4}$

זרוע מהמילים שומרים את המילה - $4 \cdot M \cdot \frac{1}{4}$
 1- $\frac{3}{4} \cdot M$ מהמילים שומרים את אורך התחילית - $1 \cdot M \cdot \frac{3}{4}$
 2- $\frac{3}{4} \cdot M$ מהמילים שומרים את אורך ה-suffix - $1 \cdot M \cdot \frac{3}{4}$
 סך כל יוצא $16.25 \cdot M$ אבל קצת חסכוני מקום
 ואם הכנסנו את האלפבית לעשרת חופש זהו.

ע"כ יש מנה דיוק בשם שיהיה לפעמים אישונים בו
 בשם זקסיקון. יש מסחר שמדבר פה. יש לקרוא אולי
 ואתה שאלו המילים

Inverted Index

הרשימה המהירה נקראת posting list - זו רשימה המסמלת לבהם מופיעה המילה. אפשר גם לשמור את המקום המסומן שבו מופיעה המילה. למשל



התוצאה של המקום נחשב מידע זה או כמובן בסיכון !!
אולי זה עדיין רשימה של מספרים.

אחריו נניח שהרשימה אחת רק ארבעה המסמכים (כלי מיקום) וכן נניח שהן מחזירות מהקטן לעדול - זה יעזור לנו בחישוב של שאלות.

סביר של אינדקס מסוג זה, אין סוג של שינוי ייחודי בסיכון הנגש, אבל זה לא נראה אישור אולי הורה הכב יעולה שלפניו.

דבר אחד יהיה קטן היא לא אישור ארבעה המספרים עצמם אלא
אם ההפרטים ביניהם. אבל אחרי שההפרטים הם גדול

הוא מספר גדול מספר המסמכים, אם משתמשים בfixed length כדי ליצור את המספרים זה לא תוסף מקום. אבל אם משתמשים בקידוד האוקטל מלמנה זה יכנס לחסוך!

סיכום דחיסה: נהגנו זה מתחילת השנה. סוגים: זה פרמטרים וזה פרמטרים. למשל, פרמטר יונה לבידול בין המילה של גווייה בקוד.

עוד חלוקה היא דחיסה גלובלית או אוקטלית. הדחיסה גלובלית
הרשימה נדחסת כאלו אלפן ודחיסה אוקטלית אפשר
להשתמש בשיטות שונות עבור רשימות שונות

נשים אם שמותם נפוצים שמופיעו בהרבה מאוד מסמכים
הפרשם של הרשימה יהיו קטנים יותר. אם עבור אותם לא נפוצו
ינחיים להיות הפרשם קטנים אם למסמכים יש איזשהו סדר
לפי הניהם.

זכר כחובת המורה שלנו תהיה זקוקה מספיק קטנים בעבור
הימים!!

מה בכל אפשר זכור? יש תוצאה אפורמט של Shannon
שאותה שהחטם התחתון הוא $\sum_s P(s) \log P(s)$
כאשר s זה הסמן! $P(s)$ תדירות המופע שלו.
אז יגידו טוב מצאנו אי אפשר. וההמשך אנתוני (ראה שיטה
שמהם מתקבלת לזה (arithmetic coding).

שיטה הקידוד הכי פשוטה היא קידוד אונרי - אך $x \in \{0,1\}$
מקבלים ע"י x אחדות ואם 0 אז 1 .

1	0
2	10
3	110

אם s אי אפשר זקוק רק וזה גם לא משנה לנו כי
אין לנו את s בתור הפרש בין מספיק מסמכים.
הוא השיטה הכי יעילה לנו? מה ההסתברות של x אילו
קידוד זה היה אופטימלי? אם רק, אורך הקידוד של x הוא
 x וזכר $x = -\log P(x)$, אם $P(x) = 2^{-x}$ אז
אז קידוד אופטימלי!

עוד שיטה קידוד היא x -coding. השיטה של x מיוצג ע"י
הקידוד האונרי של $\lfloor x \log L \rfloor + 1$ ואחריו הקידוד המקורי
באורך $\lfloor x \log L \rfloor$ של $x - 2^{\lfloor x \log L \rfloor}$. למה?

0	0
5	11001
9	1110001

אז כמה פעמים צניק בשביל זיידע אה א $\left\lceil \frac{\lceil \log x \rceil}{7} \right\rceil$?

עצמאן שיטור אלע פרמטרים. יש שגי שיטור מעגליג 88
פרמטרים - קוד האפאן קנוני וקידוד אוביגמטי...

15) 23/4/09
DB


- נאמי הקרט יש נש'מה של העשר שיטותי העיר . נא אמצאן שהם בסדר .
- א' שערזא הקלים להצאא והאות מתקדם ארשה לא .
פ

הורה לענינו : אנתנו אנסים להפין איך נדאיו אשמוי כמא גזרה של
סקס רק שנוס אבדו חפוש באפן עז .
ראינו שאפשר אשמוי אינדקס מהופך - ארים שאצבעות ארשיא
במסמכים שכן מפיעות בהם .

קוד האפמן

היסטוריה מעניינת - ציוניז האפמן העציו א קוד האפמן רבי
אז אגשר אמתון הקרט שערזא הנוא שני .

יש רש'מא סמלים אים אחד מהם (תורה הטתבה) אופס . אנתנו חכים
אמצא prefix code - קידוד אסמלים רק שאין קוד שמה חישו
של קוד אחי . (זה אפשר אשמוי פינוח הקוא) כולנו מכירים
אז האאורות של קוד האפמן . אש'ער אאורמאים רש'ו אצין
לקוד האפמן הוא אפסימל באשר חכים אמת אים סימן קוד
אש'ו .



התיסרון הידוע של השיטה הזו הוא שחייבים לשמור את העץ כפי אפסנת אר הקידוד וזה מנפח את הציכרון שצריך. ושמקוצים טקסט אס יש 26 סמנים וזה לא נורא, אבל בשביל אינדקס אותי נכזה של מספר מסמך יהיה סימבול ואס יש המון המון סמלים. ההצעה הבאה גדולה היא שיכלו להיות שורש כל רק גרע שמוא לא נכנס הציכרון הראשי...

קוד האפסון קנוני הוא קוד שחביות לא צריך לשמור על כני אפסנת. הניעין הוא שיש רשומה סמלים ונסתן שמעביר לשמור אל אחר אום אר אורק הקידוד של המאל. תכונות של הקוד:

- אם (תבונן במילוח הקוד באותו אורק אס ק אפסנת מספיק בינרוי עוקבים.
- בהינתן שני סמלים s, s' כאלו אילוח קוד באותו אורק אס $s < s' \Leftrightarrow cw(s) < cw(s')$, סומר הסדר הפנימי של אילוח הקוד מאים אסדר הפנימי של הסמלים.
- אילוח הקוד הוא שונה הקצרה ביותר היא אחוזת של אפסים.
- אילוח הקוד האחרונה הארכה ביותר היא אחוזת של אפסות.
- נניח ש- d היא אילוח הקוד האחרונה באורק i ונניח שהאורק ההס של אילוח קוד כלפי הס j אס אילוח הקוד הראשונה בסוף אורק j היא $(d+1) \cdot 2^{j-i} = c$ (סומי מוספים $d-1$ ואס דושים או הסזה של אילוח באורק ההפס $i-j$)

דוגמא: רשימה סמלים עם אורכי הקידוד שלהם:

a	3	e	2
b	2	f	3
c	4	g	3
d	4		

והוא מסתדר כמובן. צריך גם לזכור את האות של הקוד של 6
ס'מ של 101.

decoding

- $i = 0$
- Repeat
 - $i = i + 1$
 - let d be the word derived by reading l_i symbols until $d \leq c_i + n_i - 1$
- Return the $d - c_i + 1$ -th symbol (in lexicographical order) of length l_i

10001110 → א (פסגה) הצורה

l_i	2	3	4
c_i	00	100	1110
n_i	2	3	2

3	a
2	b
4	c
4	d
2	e
3	f
3	g

מהתחלה $i = 1$ ואם $l_i = 2$ $d = 10$ -

האם $d \leq c_i + n_i - 1$ $\frac{2}{2}$ האם

$$10 \leq 00 + (10 - 1) = 01$$

לכן $d = 100$ $i = 2$ - רק המשורר

אם $100 \leq 100 + 11 - 1$ $\frac{2}{2}$ האם

100 הוא המילה הראשונה שהיא אורך 3 האות של 1011000
אם aeg ובה המשורר, בעל אורך 3 האות של 1011000
שהם בדיוק מה שהיה צריך אם היינו מנסים להבין

המרחק שמה להיות לשאר איברי קוד האפוא הנני -
אז קודם אייזרים קוד האפוא ואז אר הינני

כדי לקבוע קוד האפוא צריך לזרז את ההסתברות של הסמלים
אם זה סקס צריך לעבור עליו ולספור מדינאות -
אם אנחנו נוצים את זה בשאר לקוד אר ה inverted index
והסמלים שלנו הם המספרים שמפיעים ברשימת שלנו
יש כמה אפשרויות -

1- רשמה לעשות סטטיסטיקה ישלח ולקוד אר קוד אר
כאן הקידוד יוצא טוב כי הסטטיסטיקה טובה ומדויקת ולחלופין
"מאפן איש" אר אר צריך לשאר המון נתונים אם אר
מהרשמה כדי לפענח.

2- לעשות סטטיסטיקה על הרשימה בוחצ - אז צריך לשאר רק
למה אתה בשאר הפענוח את הקידוד יוצא פשוט טוב.
3- מה שאחרים מתקבל בספרות לעשות סטטיסטיקה על רשימות
רשימות שהן מזהב באר אר. האנציקלדיה היא לברשימות
כאלה המספרים ציורים להיות צומים (נכח שהמספרים
שמפיעים הם ופרשים בין מספר מסתובב מספר המספרים
הנחל הוא קבוע וחסיס, אז אם יש לנו רשימת מאז ארוכה
סביר שיפיעו בהן הרבה מספרים קטנים ...)

קוד האפוא זה טוב ויפה ואפוא אפוא אר אם מקודים ב סוג כפריז,
אם יש מקומם שלהם זה לא יזיל - לא אם יש סמלים מאז
מאז מאז (פוזים) מספרים מאז מאז מאז (צירים).

Arithmetic Coding - הסברים במדג

דוגמה: נתונים שלושה סמלים אר הסתברות:

A - 0.2 B - 0.3 C - 0.5

ורוצים לקוד אר ACCB

Symbol	low	high
	0	1
A	$0 + 1 \cdot 0 = 0$	$0 + 1 \cdot 0.2 = 0.2$
C	$0 + 0.2 \cdot 0.5 = 0.1$	$0 + 0.2 \cdot 1 = 0.2$
C	$0.1 + 0.1 \cdot 0.5 = 0.15$	$0.1 + 0.1 \cdot 1 = 0.2$
B	$0.15 + 0.05 \cdot 0.2 = 0.16$	$0.15 + 0.05 \cdot 1 = 0.175$

ב סוגי מציאות
אחת זמנים
היומם של המציאות
עם התחביר

אם מצינו את הטווח / והקצוצה הוא אישי של מספר
בתוכו, עגל 0.175 אם בהינתן הקצו ואורך
והמילה שקיצצנו מאפשר עפצנה.

הפיצנה פשוט. הרעיון הוא שכל פעם אנשים סוגים שונים
ובדקים שהקיצוצה שיש לנו אתאים עטוח למתקנה בניתוח.

נשים זה שוק של המציאות נאן זה הבציה של מציאות
מפני הטווח ואז שיש לקצו את המציאות בצורה
היחיד ביותר.

הקיצו האנטי אתקרה אחסא התחביר של שני האורך
של הטווח המפני היא $\sum_{i=1}^n P(S_i)$ ומפני הביטוי של צורך
השבו לקצו מספר בטוח זהה היא

העיון: השבו עפצנה צורך אשחור את ההסתברות של הטאקוים
זה מוסר לציור הטוב, אבל בעיה שיתנה להיות
אתונה יותר היא שלאורך מסתק גזירות ונולד זה למנו
זה לא משנה שהמזל שלנו מאפשר להתמודד איתו.

השכיל צמחור אה הכעיוג וואה אפיל אהשמהל בקידוד
אויגאטי אצפטיביל.

התהליך קומה ובעל שלם משהחם אה ההסתברות אפי השילוק
שלו מחלקים אה הטוחים. בהתחלה אנהים שלם התווים הסמכות
להה וכה שקוראים תווים מצדנים אה ההסתברות אפי הטקסט
שקראנו עז כה. אהם זא ידענו אה ההסתברות אהן נולדה
on the fly כה שקוראים אה הטקסט.

הפיעוה מצמים בדיוק אה אהו התהליך - בהתחלה התווים שווי הסמכות
ואז משימים אנהם. כהם שלם הטוחים אצמאצמים ואובים
כאוח מהשלם הקודם ואק אין אנו אהשלם אפילסור אטעור
הניהול.

אנדקסים אבור אמהה - Web

אנהני הולכים אצור א פתח Boldi & Vigna
המסרה: אשאר א אמהה - Web וא לה כחוכן כמהה לפתור
אקוב.

פתרון (אני: נניא שלם URL יש מספר יחודי. אצ אהל
א - א ו א חיון צפים צייק אצ בויים כה אקצד אה המספר
בקידוד פאוק קבול.

אם (שאר פשוט אהט הצלעוה אהל אצ צייק אצ בויים
אם אצ אק צה נשאר ונניא (שאר אס) אצור (שימח
ל הויקים שמופיעים כו אצ אפיל אהרוד כהלי.
אם כהמאני של Boldi & Vigna אה הליטו אהרוד א
מספר הויקים איוק א - צ !!!

אמתנו מוענינו של אינקים
- אוקאלי - בדע אינקים אובותים. אצפים א אה אה
אצ אס URLs נשאים אקסקאדפיה א אקור אהמעה
כנהה יחיו קרובים.

- ציטוט - URLs בצומים לקסיקוניים סביר שיובנו זהם הרבה
לנקיט משמשים

- עקרון - הרבה פעמים להחלה חנוכים שמקושים אחרים
שלבו יש URLs עוקבים

node	out degree	successors
------	------------	------------

כשנח מה דיק אחר אחר מספר הדיקים שיוצאים? (די אחר
אחי הרשימה של ה successors (אחר)

אם זה כמות קדם אחרים כיעילות. אם השפור הרגיל
הוא לשמוע אם ה successors הרשימה הפרטים

$$S(x) = \{ s_1 - x - 1, \dots, s_k - s_{k-1} - 1 \}$$

$$s_1 - x \geq 0 \quad 2(s_1 - x)$$

$$s_1 - x < 0 \quad 2(s_1 - x) - 1$$

אם לפי האסיון של המספר הראשון אפשר

לפניה אם s_1 ואם השארם אחרי זה זה לא

בעיה אפשר

השפורי הכא הוא כזה: יחל אחריו לפני x היה קיצוץ y
שנשיא ה successors שלו דומה לזו של y ואם אולי
לא רצאי פשוט לשמוע אם $S(x)$ אלא להגיד אשמו
מסמך ה - successors של x הוא כמו של y אב

אחר השנייה הבא

reference number - $x - y$ -

copy list - הוים באוק $S(y)$ למחיקים איסר

ה successors של y הם גם של x

- רשימה של קיצוץ (זים הסרים) - $S(x) - S(y)$

(19)

ואז העברה שלנו הופכת ל-

node	out-d	ref. #	copy list	Extras
------	-------	--------	-----------	--------

אז הייצוג הזה אנונימי כוזבים לזכרון כי רשמה הקטן
 הן צי הכבוד. אז במקום זה (מגבש) זה כסדרה
 של חילופים בין רצפים של 1 ו-0. אז אפשר להשתמש
 בקידוד הפשוט מאוד פשוט מה האזורים של הרצפים
 נאחה. בהנחה שהרצף הראשון הוא תמיד של 1 (אזרחים
 יכולו להוציא 0) אין בעיה אפסות אז זה. ואז מקבלת
 טבלה

Node	Out-d	Ref	#blocks	Copy blocks	Extras
------	-------	-----	---------	-------------	--------

אישיו נרצה לזכור גם את הרשאות של הקולקציות הנותרים.
 נרצה לנצל את צג שהרבה כעמים יש גם רצפים אקראיים.

בלים זכקשה ארצק של הכירה - באתר

ף

ציהרני אר צוכים לאנצקס אר ה- web וראני פאחון

שלשמש ה-3 ביטים זכור link

נאליים זכ שמצגה יש טבלאות שלחיתקלג אהמטאר הלקורג

יש שלם כמה typods חול מצה אר הזמורה node

לא באאר צריק לשאור כי אלה בשט מספם זקקבים

נניי שחוצים ארצג אר יש אינק בין א-ז. הינו חוצים

אלה זשורה אר וזכק אר אופיו של אינק א-ז. אהל

פה יש שגי בעיורג

קוצם א, אי אפל סתם ככה אלה זשורה א כי אנהנו זא

יוצרים אפה היא מתחילה. שניג, זכ אר יחלנו אלה יש

זשורה א אר הקידוד הוא ככה להכשילור של שורה כלפי

גלויור מושילור של השורה הקלצמור. זכ כדו. ארצנה אר

הטבלה אין הכירה אלא זקרוג באופן נזיל מההתחלה

אני הזמנה מאוד קלמפקאי ה- storage אהל קלש אהוציא

אחני מיצג ה- random access

ף

Wild Cards

כאני איק מוצאים אר רשילי הזממנים שלחולים אר המילה

ז. זה היה בשט זאז- זחש סקסקון זאז אהמט

inverted index

אהל הינו חוצים זכ ארצג אר שאלתה אהצורה *ab אר

or, בומר ושיש אני wild cards במילה

אז ארצג אר *ab זה קל כי הלקסיקון אחיון אר

אז אנהנו בשט יחלים זמצוא אר אר המילים שמתחילור ה- lab

ואז אפילו בדבר המקורי... אבל כדי לערוך את *os* איתנו
 נצטרך לעבור לעמוד על הלקסיקון. השבוע אפילו א—
 זה אפילו ישמור את האנציקס העצמיים - פתח את המוקד
 ופתח את הלוקסיקון הפוך. אבל זה לא עוזר לנו לערוך—
 על שאלת מהצורה *lab* ...

n-grams

n-gram זה רצף של n אותיות עוקבות במילה. נסמן
 ב-\$ המילה מילה או סוף. אם ה-digram של $\log$ הן
 $\$d, do, og, g\$$

אם אם יש לנו מילה מילים אפילו ישמור השבוע א—
 מילה ב ה-digrams עם קישורים למילים שבהן הם
 מופיעים. אם כדי למצוא את *r* lab איתנו צריכים
 למצוא את המילים שמשתפות למילה של \$r, ab, la, l\$,
 ונסוף צריך למצוא מילה שמצאנו את המילים ולשלוט...

מה הסיבוכיות של הדבר הזה? נניח ש-

* 30 אלגוריתם כולל \$

* 10^6 מילים

* אורך מילה ממוצעת (ללא \$) הוא 5 אלגוריתם

* הנוף אלגוריתם הפוך היקר מופיע ב-10,000 מילים

* 600 מילים אלגוריתם מופיעים במילים בלבד

* מציבים טבלה 32 bits = 4 bytes

איתנו—

* צריך 5 ביט לאגור כי $\lceil \log_2 30 \rceil = 5$

* צריך 20 ביט למילה (למילה מילה) כי $\lceil \log_2 10^6 \rceil = 20$

* הרשימה הארוכה ביותר היא האורך שייצוגו טבלה 14 ביט

$\lceil \log_2 10000 \rceil = 14$

(21)

המנה הכי פשוט הוא טבלה

letter pair	length	words
-------------	--------	-------

אם יוצא

$$600 \cdot (5 + 5 + 14) + 1000000 \cdot 6 \cdot 20$$


סך האותיות
 סך אותיות
 אורך המילה
 מספר המילים
 מספר אותיות
 מספר אותיות
 מספר אותיות

= 120,014,400 bits

אם צאן הישג המנה? אי אפשר לעשות חיפוש בינארי כי הרשימה לא באורך זהה. רק צאן הישג הוא אינארי. (חשוב להבין את הדברים האלה כי שאלה דומות מאוד להופע במבחן!).

אפשר אפשר - נוסף 600 מציאות. קופסה כזו היא אחת מהצורות היותר טובות. חיפוש בינארי. ה-scope של הקלות זו הצורה מצוינת אבל חשוב לעבור לבדיקה אי אפשר להציג על מקלם סתם ככה. הצורה היא ברורה של byte אותו אנחנו צריכים להבין ברמה של bit זה טלוי אפקטים סיבוכים...

הצורה אחרת: ארוס 900-30-30 מציאות. אלה הם אותיות אפילו והם מציאות ארוגות. אלו (שמו) 900 פונקציות. אפשרות רשימה ארוכה של רשימה.



ואם הליכרון שלצדק הוא $900 \cdot 32 + 6 \cdot 10^6 \cdot 20$ וצאן הישג הוא אינארי!!

Rotated Lexicon

ואינו שהבניה הפתרון הקצב שלחתי למצאני את הרשימות
 צריך לעבור על כל המוצאי שמה שקובלנו אך למתאים לשאלתא
 גם Rotated Lexicon אפשר לענות על השאלתא עם תפיש
 מנאכא אתר.

אם יש לנו אותה נשמור את ה"סימבולים" שלה לפי סדר
 הא"ב. עם סימבול כנה למתאים צ"ל. (הסימבול, התיאור)
 ואפשר לשמור את הציורה ואת המספרים כדי לעשות את
 החישובים המסובכות בצדק ורק אפשר לעשות חישוב מניאכא.
 אז למשל בשביל לתפיש את ab^* (תפיש בלבד) ה
 את ab^*

כדי למצוא את

ab^*

$*or$

$*ab^*$

$|*r$

$|*b*r$

(תפיש את

ab^*

or

ab

r

r ב ה

אז אם יש לנו wild cards במאצא זה נצריך
 שני חישובים: אחת, את המספר המקרים מספיק רק
 חישוב אתר.

נניח רוצה שמנסה לענותים הקצבים, ונמנה האוכה
 מ"הגה היא באוק. 30. אז כדי לעצב סימבול צריך

5 ביט. ואז אצל הקסקון. פה

$$1000000 \cdot 6 \cdot (20 + 5) = 150,000,000$$

↓
איות

↓
הפעולה

↓
מספר המקרים

↓
סימבול

אז הרכבה יותר סיבוכי מאשר להמנה הקצבים. אבל מצד
 שני זה השאלתא פוזרמא.

תיקון שגיאות כתיב

- גבי מסור זיקריות:
- לתקן שגיאות כתיב לפני שמאנצקטים מסמך (בצב לא עושים)
- לתקן שגיאות ותיב בשאלות (בצב לא מתקנים אוטומטית אלא מתלים בצעה)

יש שני סוגים:

- isolated word - מתבאים על מילה בנפרד
- Context Sensitive - מתבאים על מילה בתוך הקשר

להחלפה מהיכנס להיות אנו עושפט כמו

I flew from Israel to Italy

- אנחנו נצטרך רק על תיקון של אותים בוצצוג.
- השני עשים זה: אפס זה שמעם באיזה סאנצנו יוצעים
- מאפה הגיע המסמך. עמלל אם המסמך הגיע מ-
- OCR אז יש סיכוי גדול להתקבלת בין O - D
- כי הן צומות דאם המסמך הוקלד (QWERTY - כ)
- אז יש סיכוי גדול להתקבלת בין S - I - D (כ)
- הן צומות על המקלדת

ההנחה הבסיסית שלנו היא שיש עקסיקון שמאץ משיעור

המילים הכתוב הנכון. את העקסיקון הזה אפס זהביא

אשני מקומות

- עקסיקון סאנצטי כמו מילון או עקסיקון סבצפי לתתום
- גדשיגי לשון

- עקסיקון שנוצר מהסתריות בקורפוס מסומים (למשל ב
- האינטרנט) כולל שגיאות כתיב שמופיעות שם וכו'.

23

edit distance

הבעיה היא: כמה פעמים צריך לערוך אותה, אחת הערכה שלהן
הוא מספר הפעמים המינימלי (הכנסה, מחיקה, החלפה)
שצריך לבצע כדי לקבל מ- s ל- t .

לדוגמה, $\text{edit-distance}(\text{"cat"}, \text{"dog"}) = 3$

$$\text{edit-distance}(s, t) = \max(|s|, |t|)$$

חישוב האותיות:

1) $n = \text{length}(s)$

$m = \text{length}(t)$

if $n = 0$ return m and exit

if $m = 0$ return n and exit

2) המשיך במחשבה דיון צינור שלמה...

צינור:

		G	U	M	B	O
	O	1	2	3	4	5
G	1	0	1	2	3	4
A	2	1	1	2	3	4
M	3	2	2	1	2	3
B	4	3	3	2	1	2
O	5	4	4	3	2	1
L	6	5	5	4	3	2


איך מוצאים את המרחק?

המרחק! הפעולה של צינור הוא
מחליף את ה- u ב- A ומוסיף L .

אפשר לעשות אישור קצר יותר למילים - אחת אחרי השני
 והחשוב מסווג - כולל יותר מאלו והאחרות צומות

בסופן בולדאי זה נראה לעמוד על הדיסטנס והמרחק
 והחלפה בין קרבה ורחוק של המילים
 אז אפשר להסתכל על n-grams של שתי מילים
 ואז להסתכל על Jaccard - $\frac{|X \cap Y|}{|X \cup Y|}$
 אז קודם נחפש לואג מילים שנקרא Jaccard
 נשקלן הוא מין של מילים ואז נבדוק ביתר פירוט.
 (בדיוק המילים הם מהירה).

נשים את n-gram index לא מופיע המילים
 עצמן. אלא המספרים המציינים שלהן. אז אם אנחנו
 יוצרים את אובייקט המילים אז אפשר להשתמש



אזכור זהו ציור מילוני של מילים באמצעות
 AND, OR, NOT

במילים יש קונ'קטיביות אם יש לה שני רק AND

(24)

כדי לשלול את האפשרות של קיום
למעשה אין הסיקור והשאיפה את התצפיות של המעשים
וההתקוות שלהן ואם אובדים עם המעשים מונחצ'רה
היותי לתצפיה ביות ומעדידים מהרשימה שלנו את
המסמכים שהמעשים והאחרות לא מופיעות בהם.

אחרת, מעשים מהנדרים כי זה מוסק ממך. אנוני דולרים
על ידי פרשימות האירועים עם כמה שפתוח צרכים לבדיק.

נניח שיש לנו שתי רשימות מסמכים U , V ראש U
קציה n - V .

אם הרשימות ממורכזות אפשר למצוא את החיתוך שלהן
ב- $O(n \log n)$.

אם הן לא ממורכזות וב- V אפשר לעשות חיפוש
במגדל U אפשר לחתוך אותן ב- $O(n \log n)$.

בפועל במחירי הנתונים שאנחנו בקורס אין לנו
Random Access אך אי אפשר לעשות חיפוש
במגדל ונשארו רק עם האופציה האחרונה.

ההצעה היא שיהיה U רק יחיד...

25) 7/5/09
DB

- התרחושים לא (בדקים)
- האתר הקורס יש הקטגוריה וההצגות
- ננסה להציג את פתרון התרגיל וסוף השנה השלישית



Query Processing

אנחנו רוצים יוצאים צרכים שלנו לשלוח איזה בקשות למהם
אנחנו רוצים לחפש זה נשמע פשוט אבל רשית כמויות גדולות
לא מידע רב צריך לחפש פתרונות לא טריוויאליים...

הצרכים שאיננו רוצים להם קוויקליב'ג. זה
הפתרון הוא תהליך חוזק בין posting lists
צרכנו על שתי אפשרויות:


- מחבר איננו על שתי הרשימות (המחברים) ומצאנו החיבור
אם מחבר איננו יחד לקחת הרבה זמן
- זו הייתה לנו ידועה אישה נמצאת א: posting list
השני, אם מילה במיליון אפילו אישה תפוסה פונקציה של
ואז זה יוצא $(\log |I|)$ שזה לא אס' ווא
קטן! - $|I|$ גדול
- אם אין לנו יכולת אישה נמצאת אישה וזה אישה
סיכור

- הרשימה היא רשימה הפרטים וצריך לזה אחוז רדי
אפילו
- הרשימות אינן באורך זהה ואם אי אפשר לדעת
אשר המצב של הרשימה

איך הם לא נוס אישה אישה מחירה יתכן?
איננו אוצרים: (נוי שיש לנו רשימה מקושרת ואם יש לנו
מחברים

הם מצביעים ל node הבא את רכיב זה node
באמצעות חייבים לעבור על אלה שמתחילים
נוסף עוד קצה פונקציה:

- זה קודקוד שני יהיה פונקטור עם קודקוד שני הבסי
- עם קודקוד רביעי יהיה פונקטור לקודקוד רביעי אחריו
- ובקיצור זה קודקוד 2 יש פונקטור לקודקוד שנמצא
2' קודקודים אחריו.



זה כמובן מופשט למן חיפוש אידיאלי על חשבון נוספה
של $O(\alpha)$ פונקציה
כיום המצביעים
מאפשרים לעשות
קפיצות לאורך

הנוספה/הקטטה הראשונה בצורה הם מאוד בעייתיים בג
דברים לעדכן את הפונקטורים אבל כאמנה נתונים סטטיס
בה מאוד נחמד.

יש גיאציה של המכונה בזה שנקראת skip list
(יש מאחורי קצה ונחמד) שמעמדה כרדואלית ומכונה
אמור יעיל בהסתברות גבוהה.

בצורה ישירה אין אפשרות להשתמש במכונה ולזה רצו לשמור את
ה skip list postng כי ה postng list הוא
ושימור הפרטים אבל נניח שזה לא שמור בהפרטים
מט לא, במשך רמה שבוטור התאמצנו מאוד לחסוך בביט
המכונה נתונים ודושיי המאנו מכונה נתונים שמרפוא את כחור
הזיכרון. אז אנחנו לא נשתמש ב skip list.

אבל נשתמש בדינאמי של הפונקטורים כדי לשפר את זמן הרישום.

נקודות סיכום

נקודת סיכום ב- `posting list` היא `<docId, bit address>`
 ומש `docId` זה ה- `docId` של המסמך הנלכתי! `bit address`
 זו נותנת זנקציה לסעיף הנבחר. רצי לחסוך אפס של
 אגרה כהפרשים אוקציה הסיכום הקצמור. ובה אפס של
 להתקדם ברשימה.

אבל מה אם השתמשנו בשיטת קדוצ? קיצור זאמם וקיצור האפס
 מקוצרים ב מספר הנפח. אז זה מספר. אכן קיצור אריתמטי
 מגיעים לט הושיא. כאובייקט אחד ומקוצר אלה כמספר אחד,
 אז שם אי אפס יהיה לקפל לאמצע. אז זה משמל שצריך
 לקחת בחשבון...

ושוב כדאי יש `trade off` בין מספר המור המצבים
 לבין הזכרון. נניח שהמצבים קופצים פסם x אפס x אומנטי
 ויהי א אוק הרישאה. מספר ההשוואה הוא $\frac{k}{x} + x - 1$ אז
 זה אומנו חוצים למספר אז בוחנים $x = \sqrt{k}$

שאלות לא קולנוקציה

כאומן היינו חוצים גם להקנים ולשאלה `OR` או `NOT`
 אם יש קולנוקציה של דיסיונקציה משארים את הקצבים של
 הדיסיונקציה ע" סכום המצבים של אותה בתוך ו-
 משמרים בדומה לשאלה קולנוקציה נשמסתים של דיסיונקציה
 כהיפוך האד. דמ זה דומה לשאלה אחרת של שאלה לא
 נניח שיש לנו קולנוקציה `wild cards` אומנו לשאלה של
`wild cards` אומנו למשל אומנטי אפס המלים סקסקון
 שינסור להקנים. ואז למשל `*a` and `*a` הופה למשל
 ולשאלה של קולנוקציה דיסיונקציה

בשאלות אד כה שפאני כאן הירדה למיד היה לם הוצה אומנטי
 כאומן הרישאה של המלים. האמה תמיד נסון? לא!!

שיתור למחזור NOT יתור לקחה יותר זמן מאשר הרשימה
של האות, כי יתור להיות לרשימה המסומנים שמה לא
אופיה בהם הרבה יותר ארוכה מרשימה המסומנים לשם
כן אופיה בהם. לכן אנוני חפוש בצב לא מאפשרים
שיתור כזה. זה נקרא שאילת לא בטוחה.

יצירת האינדקס

יש שני נושאים שצריך לדון בהם

- מצאג המסומנים עצמם (crawling)

- בניית מבני הנתונים. אופקשה!!

• אין מספיק סימון והחזיק את האנדקס ואם יש

הרבה page faults

• posting list צריך להיות רצף ביססון. אבל

במל שאנחנו עושים צמיסה אנחנו לא יוצאים מאגש כזה

מקום זה יקח את אנחנו לא יוצאים מאגש מקום אחר

אם אפשר למנוע את זה בצורה הנאיבית - לקרוא מילה מילה

וזחול המקום הנכין ה- posting list יש ממש

חשש רבד של thrashing - להתכוננותה את זה

הזמן הדרושה ורתיבה לדסק.

אנאויציה לפתרון:

- בניית הקטקסון היא לא קלה כי הוא קטן

- בשביל ה-inverted index קוצם יוצרים צוגר של אותה ומסמק

ואם אם ממינים את זה לפי המילים את המקומים שלהם

סדנתי שאם לא עבד בקלור... הולק הקלף הוא הליון כי

המציג לא נקט לזיכרון הרשי. אבל הם ספר ה- ב

יתום איך עושים מיון במקרה הזה. אז סימנו.

Crawler

מטרה

- להוסיף רחוב ג'ואי של דפים (אם הרשם לו לה היה אפשרי)
- לעצב את הדפים שבהם הגדל
- למצוא דפים חדשים
- לוודא שיש להם שיתר "דפים טובים" שזה משפך שזוג צדק אהדדי

רעיון בסיסי: אגרומים עם קבוצה גדולה של URL-ים שמם

אולם בתור ואז עוברים להתור רק:

- מוצאים URL מהתור ומחזירים אותו

- מוצאים את הלינקים שמוצאים אליהם

- מוסיפים לתור את ה-URL שזוג ואותו בלב

ואם זה נושם עד לתור ריק

התפוקה לא באחר מסתירה כי אם זה שוב לא הרשם

נמשכו אינסוף - דפים בלחץ מוגזם / נוספים

אם מקימים אתר אינטרנט חדש אבל אין אחד לא מציג

אז, אנחנו רוצים להיות בתים לא יחידים אנוש גישה בלי צדק ימים

אפשר אנוש להיות יצירה ומנוח חפוש אבל אנושם לעצב

הזה לא "שטורצמן" רב כג. לה של אחד לא מציגם אליו זה

בכך את אומר שהכל זה חלום...

אוקי ואנחנו את התור של ה-URL-ים? יש הנושא הזה הרבה מחקר

האסטרטגיה הבסיסית

- מחסירה - מכניסים לתחילת התור ומוצאים מחסירה התור

זה מאפשר חיפוש ארוך

- תור - מכניסים לסוף התור ומוצאים מהתחלה. זה מאפשר

חיפוש ארוך

רוחב vs עומק - אין אחד מהם שיטה טוב באופן
 מוחלט. עם זאת יתרונות מלאי תיפוש (רוחב "היכן" יתר -
 לא "גב ציף" יק באתר אחד ואילו בחפוש לעומק יש
 זיקיות של התקשורת וזה תוסף למן על DNS. עוד יתרון של
 תיפוש (רוחב) הוא שזמנים קצרים על הדפים ה"רדודים" יתר -
 בחיפוש (עומק) יתר מסביר שהם חשיבים יותר כי בעזר שלבים
 אינרים השלבים המלאי. חיסרון גדול של תיפוש (עומק) הוא שלבים
 כל המאן פונה לאתר אשר המאמץ אותו מסודר וזה ממש ידוע
 לעומתו denial of service, וזה לא רצוי כי הם עלולים
 להתעצבן ואז לחסום ממש את השירות ולפגוע האוניברסיטה
 או משרד רזה. אז מי שפונה crawler - שיילכה

- תור קרימיון

- interest driven - יש רשימה מילים שמאגרת נשט
 שמצוין אותו ואם הם כל מה צריך לפי הדימיון שלו
 ורשימה המילים הנשא. ואז לפי הדיוח אהבנים אתר.
 הפעם היא שאנחנו רוצים את הדיוח בלי אהבנים או הכל
 אז אפשר אולי להסתמך על הדף לעצבים אלו...
- popularity driven - הפציה נקבע לפי כמה הלינקים
 אליו נכנס
- location driven - לפי מילים שמצויות מתקבצת (כמו
 .ac, .edu) או (מורג"ל) מתקבצת - נכל שיש
 "אתר הדף עומק יתר ונראה שהוא חשוב פחות..."

מה זה לעקב את ה crawler?

- ציוד לעקוב את ה IP בעזרת DNS
- ציוד להתחבר אליו ולשלוח או בקשה
- ציוד לחקור את השפה

בשמן הקריאה את ה DNS lookup אפשר לעשות

caehing & תחבורה DNS . חול אמה

אפשר גם prefetching (להקדש אמה ק' בשמכניסים)
(חברת דאדשמוזילא)

רפסחים אנשים כודם אמה תורוור - crawlers - ואמאם

זהם אמאם ככל, לא אמאם להם לאנדקס, אמאם רק לחק

מה - crawler-ים אמאם אמאם וזוז. שמוצאם אנוס אמאם

להקדש להקדש הנחלים - אמאם להם ב - root directory

א האמר קולד להם robots.txt ושמיש תורוור -

זמאם א שמוצאם - ו-URL-ים למאמר להם אמאם

אמאם א. אמאם לא אמאם אמה התנאים האמה!

חול אמה בם צל HTML אמאם אמה תורוור לזמאם להם

כאמאם אמאם בקלם אמאם: אמאם meta-tag למאמר שמוצאם

אמאם אמאם אמאם בו שמה אמאם אמאם

כמו שמאמרני אין צוק אמאם אמאם שמה אמאם אמאם

אין לא אמאם - שמוצאם בם אמאם. צוק אמאם אמאם אמאם

אמאם אמאם אמאם

למאמר אמאם אמאם

- ונ"ה שמאמרני עושים שמוצאם ותורוור צל אמאם אמאם חוק

שמוצאם אמאם robots.txt אמאם יחלים אמאם אמאם אמאם

כבוור וצרים? כ!! אמאם חיה אימה אמאם שמוצאם הפסדו

בו אמאם אמאם חדשה או אמאם אמאם

- בוודאי אמאם אמאם אמאם אמאם - robots.txt יחלים אמאם אמאם

- ככל אמאם יחל אמאם אמאם חק. שמוצאם שמוצאם

בם אמאם אמאם שמוצאם אמאם, אמאם אמאם אמאם

אמאם אמאם אמאם כחבורה IP אמאם

- אין אין צוק אמאם אמאם אמאם אמאם - שמוצאם - ספצים

אמאם...

המאמר ש תרשים כחמה של crawler

באינטרנט יש המון דפים עם URL-ים שונים אבל התוכן שלהם זהה או דומה (mirror sites).

(מאגר הוא הימנע מהדפוס את אותם הדפים מאקומוג שונים - זה אצל המון מילאבים וזהו גם מהדפוס אור איכות התוצאות - איך אפשר להתגבר על זה?)

- דומה אינו תוסה גנואלג של ה URL-ים. זה של `index.html` זה אותו הדבר.

- ושאור hash של הצל ואז נשלח צל חדש אם צריך. hash שלו לא קיים. אמנם זה לא מונע מאיתנו להוריד את הצל אבל לפחות לא נשמתי אלו. רק נשים אם יש פונקציה חיבור (אשל MDS) שמסביר להתנהגות אצלם מאוד קטן. זה אומר רק לפרוי דפים זהים אמנם זה לא "רמזי זהים".

- (נסוג) אצלם דפים כחצו זהים. האמצעו edit distance. זה דומה לא זמן נשים מילוני דפים (זה גם לא קצרים ב רק. א אחינו נדבר על פחות אתר - זה צל ילדים הקציר רק שאם דפים הם דומים אז ההסתברות גבוהה יש להם בדיוק אלו הקציר.

Shingling

ההינתן מסמך D , w -shingle היא מחרצ של מסמך מסומק N . $S(D, w)$ הם ב ה w -shingles של D . (אזיר צימין של A ו- B).

$$r_w(A, B) = \frac{|S(A, w) \cap S(B, w)|}{|S(A, w) \cup S(B, w)|}$$

זה ה-Jaccard Coefficient !! נכל ש- w קטן יותר איתנו מתינים יותר איש יותר סבבי שממכים רבים יצאו דומים. הצט ממששים ב. $w=7$.

הפעיה בסגור לקוח את (SD) היא שהקבוצה יתרה להיות.
 מסווג ידועה. אז אנחנו (כזה לדגום את הקבוצה האלה רק
 לצימין הקבוצה יתרה של צימין במסמכים.
 לדגום Shingle סתם ונדעלם זה לא טוב כי אם יש לנו שני
 מסמכים מאש זהים אם ה Shingle ים, והסתמכים אחר
 את אולי אחד היא $\frac{1}{n}$ זה לא טוב לנו.
 אפשרות שיש ב Shingle ים האפליים מוגדר סדר
 חלף. אז למשל התקציר יתה להיות ה Shingle הכי קטן
 (הכאן מסדר האלה) ואה Shingle הכי גדול. (האחרון
 מסדר האלה). זה יתבאר למסמכים זהים אולי יש סכומי גדלים
 שנתלים למסמכים מאש לא נותנים יצאו נותנים.
 אז אנחנו רוצים לבסתר את זה Shingle ים. בדף אשלמלים
 ה-100. (הסמך המצטרף).

אנו עי חיסול בדגם אשלמלים במה Crawler ים. אז
 צדיק לדגום מסדר את ה URL ים בין היתרים השלים
 כדי לשם יבול אחרים קוד.

—

Figure 1

$\frac{1}{2} \times \frac{1}{2} = \frac{1}{4}$

1. *Chlorophyll a* (Chl *a*)

Condition	Control (n=10)	MCI (n=10)	AD (n=10)
A	100	85	65
B	95	80	60
C	90	75	55
D	85	65	45

Condition	No feedback (%)	Feedback (%)	No feedback + feedback (%)
A	~75	~85*	~85
B	~70	~80*	~80
C	~75	~85*	~85
D	~75	~75	~75
E	~75	~75	~75

1. *Chlorophyll a* and *Chlorophyll b* were determined by the method of Arar and Collins (1971). The concentration of chlorophylls was expressed in $\mu\text{g mL}^{-1}$ of the sample.

Age Group	1980	1990	2000	2010	2020
0-14	25	22	18	15	10
15-24	20	18	15	12	8
25-34	15	14	13	12	10
35-44	12	11	10	10	10
45-54	10	10	10	10	10
55-64	8	8	8	8	8
65-74	15	18	22	28	35
75+	5	5	5	5	5

Protein	Total protein (%)	Cytosol fraction (%)
Actin	~10	~10
Myosin	~15	~15
Formin	~20	~20
Arp2/3	~25	~25
Wiskott-Aldrich	~30	~30
Other proteins	~40-100	~40-100

Ranking

המטרה שלנו היא להבין איך אדרג דפים. אדרג דף הסתמכנו על שאלות
כמשפט העל-אני - או שלכל מראית או שלא. במי משתמרים וסדר של
התוצאות. את סדר של web או אפילו האוסף לא מסווג
הדרג של קבצי טקסט זה לא מספיק. היינו חוצים את ציון של
הקצאה וההתנהגות את התוצאות מסדר דפי ציונים.

אדרג שני, רלוונטיות זה אפילו סובייקטיבי. לך תחליטתם "אדרג. אדרג
החפשים מנסה לעשות הערכה של מה רלוונטי ומה לא

המנסים למדוד סים של אדרג יש כמה מדדים סטנדרטים

- ציון - אחוז התשובות הרלוונטיות מכל התשובות שהוצגו

כאמור נרצה להצביע יהיה רמה שיותר גבוהה

- recall - אחוז התשובות הרלוונטיות שהוצגו מכל

התשובות הרלוונטיות

- ציון ב. א - אחוז המסמכים הרלוונטיים מבין א התוצאות

הנשלטים.

איך אפשר לקבל ציון מושלם? - לא להתחזר כלום

איך אפשר לקבל recall מושלם? - להתחזר הכל

אז יש הציון יהיה recall במים אחד על חשבון השני.

אפשר לחשוב את המדדים האלה אוטומטית כי אדרג החפשים

לא יודע מה רלוונטי ואילו הוא היה יודע אז התוצאות שלו תמיד

היו מושלמות.

אז איך הם לא?

אם פיקציות הדדיות אפשר להזדמן לחיך לשני קבוצות - גאוגר

שחורא (בהנחה שאחראי כל מקומות ציון) וטענות האנליזה

השאלות לא צל יש ציון אבסולוטי. (פיקציות גאוגר שחורא

כאמור הרבה יותר יקרה לחישים, אולם האנליזה אחרת

שזה דיווח יותר מוצחן. Page Rank לא באמת נותן תשובה
השאלות: ודיווח הדיווח הזה לא באמת נותן תשובה
שזה עובד יותר טוב מדיבורי בלבד.

TF-IDF

זה מזהב כל מסמך יש משקל W_{td} וזה מזהב כל מסמך
יש משקל W_d . המספר הוא זה הדיווח W_{td} .

אם המילה t לא מופיעה כלל במסמך d אז $W_{td} = 0$.
לשאר המילים אתה משקל t אבל זה המשפטי. כי כן

למילה הדיווח יש משמעות גדולה יותר ממילה (דיווח) אחר.
היינו כוונת W_{td} יצא את מספר המופעים של t ב- d .

אבל זה לא מזהב מסמך מוצחן כי יוצא למילה שהדיווח
1000 פעמים טבעה ממילה שהדיווח 1000 פעמים

אז המשקל הסטנדרטי למשגמים בו היא $W_{td} = 1 + \log f_{td}$
נשים את זה על המילים שונות. צריך זה איזו דיווח

מילים נדירות (בשפה).
מילה t נדירה או f_t זה מספר המופעים של t במסמך

הם ואז נדיר $W_t = \log(1 + \frac{N}{f_t})$
נרשם יש על המשקל, זה נדיר אתם 3 משמשים במסמך

מחלקת אחר. מסמכים ושלילתיהם יקראו כ- n מסמכים.
ואם n מספר המילים במקסימון. במקום ה- k של הווקטור

של מסמך d מופיע המשקל W_{td} ואם t היא
מילה ה- k במקסימון. במקום ה- k של הווקטור של

השאלות מופיע W_t ואם t המילה ה- k במקסימון.

צילומי: $N = 210, f_a = 30, f_b = 210, f_c = 70$ - ל

Doc 1: aabbdd


Doc 2: bcccc

	A	B	C	D
Doc 1	2	2	0	1
Doc 2	0	1	3	0
query	3	1	2	0

השאלות היא abc

ייתכן שהמקסימון יהיה שזה
דומה. מופיע מופיע

- 3) אז יש לנו וקטורים של מסמכים ושל שאלות. נניח לדוגמה:
 כמה הוקטורים של המסמכים קרובים לוקטור השאלה? אולי
 זה נמצא דרך כלשהי לבין הוקטורים.



$$\cos \theta = \frac{\sum x_i y_i}{\sqrt{\sum x_i^2} \sqrt{\sum y_i^2}} = \frac{\langle x, y \rangle}{\|x\| \|y\|}$$

במסמכים שלנו ווקטורים

$$\cos \theta = \frac{1}{|Q| |D|} \sum_{t=1}^n w_t w_{td}$$

אם וקטור אופייני במסמך היחידה של המסמכים והמסמך
 למעשה אומרו רק זה שווה אפילו פשוט להתעלם ממנו.

	A	B	C	D
Doc 1	2	2	0	1
Doc 2	0	1	3	0
Query	3	1	2	0

(המשקל צריך להיות)

$$\frac{\sum w_t w_{td}}{|D|}$$

הציונים של המסמכים

$$\text{Doc 1} : \frac{6+2}{\sqrt{9}} = \frac{8}{3}$$

$$\text{Doc 2} : \frac{4}{\sqrt{10}}$$

אם Doc 1 אחרת דבר יותר.

צריך דבר הנחשף שיש לנו רק טקסט אבל ב-web יש אאאאאא
 של html (כמו הכותרת של הדף, מילים ב-bold או
 italic) שיהיה להם ערך בהתאמה. אם אפילו
 למשל אם המשקל של מילים שמופיעות במקום מסוים. למשל
 אולי למילה מסוימת צריך לתת משקל דבר יותר.

דוגמה נוספת היא להשתמש ב-anchor text של עמודים רבים
 להבין משהו על הדף. אם אפילו למשל להשוות המילים האלו
 (ואולי רק אחת מהן) הדף והעמודים אולי עוזרים יותר להבין

כחול.

אז ערשט האבן שטח צו זיין שטח
נאכדעם צו זיין שטח. דער צווייטע
שטח איז דער צווייטע.


אפשרות 1 - P_1 - P_2 - P_3 - P_4 - P_5 - P_6 - P_7 - P_8 - P_9 - P_{10} - P_{11} - P_{12} - P_{13} - P_{14} - P_{15} - P_{16} - P_{17} - P_{18} - P_{19} - P_{20} - P_{21} - P_{22} - P_{23} - P_{24} - P_{25} - P_{26} - P_{27} - P_{28} - P_{29} - P_{30} - P_{31} - P_{32} - P_{33} - P_{34} - P_{35} - P_{36} - P_{37} - P_{38} - P_{39} - P_{40} - P_{41} - P_{42} - P_{43} - P_{44} - P_{45} - P_{46} - P_{47} - P_{48} - P_{49} - P_{50} - P_{51} - P_{52} - P_{53} - P_{54} - P_{55} - P_{56} - P_{57} - P_{58} - P_{59} - P_{60} - P_{61} - P_{62} - P_{63} - P_{64} - P_{65} - P_{66} - P_{67} - P_{68} - P_{69} - P_{70} - P_{71} - P_{72} - P_{73} - P_{74} - P_{75} - P_{76} - P_{77} - P_{78} - P_{79} - P_{80} - P_{81} - P_{82} - P_{83} - P_{84} - P_{85} - P_{86} - P_{87} - P_{88} - P_{89} - P_{90} - P_{91} - P_{92} - P_{93} - P_{94} - P_{95} - P_{96} - P_{97} - P_{98} - P_{99} - P_{100} - P_{101} - P_{102} - P_{103} - P_{104} - P_{105} - P_{106} - P_{107} - P_{108} - P_{109} - P_{110} - P_{111} - P_{112} - P_{113} - P_{114} - P_{115} - P_{116} - P_{117} - P_{118} - P_{119} - P_{120} - P_{121} - P_{122} - P_{123} - P_{124} - P_{125} - P_{126} - P_{127} - P_{128} - P_{129} - P_{130} - P_{131} - P_{132} - P_{133} - P_{134} - P_{135} - P_{136} - P_{137} - P_{138} - P_{139} - P_{140} - P_{141} - P_{142} - P_{143} - P_{144} - P_{145} - P_{146} - P_{147} - P_{148} - P_{149} - P_{150} - P_{151} - P_{152} - P_{153} - P_{154} - P_{155} - P_{156} - P_{157} - P_{158} - P_{159} - P_{160} - P_{161} - P_{162} - P_{163} - P_{164} - P_{165} - P_{166} - P_{167} - P_{168} - P_{169} - P_{170} - P_{171} - P_{172} - P_{173} - P_{174} - P_{175} - P_{176} - P_{177} - P_{178} - P_{179} - P_{180} - P_{181} - P_{182} - P_{183} - P_{184} - P_{185} - P_{186} - P_{187} - P_{188} - P_{189} - P_{190} - P_{191} - P_{192} - P_{193} - P_{194} - P_{195} - P_{196} - P_{197} - P_{198} - P_{199} - P_{200} - P_{201} - P_{202} - P_{203} - P_{204} - P_{205} - P_{206} - P_{207} - P_{208} - P_{209} - P_{210} - P_{211} - P_{212} - P_{213} - P_{214} - P_{215} - P_{216} - P_{217} - P_{218} - P_{219} - P_{220} - P_{221} - P_{222} - P_{223} - P_{224} - P_{225} - P_{226} - P_{227} - P_{228} - P_{229} - P_{230} - P_{231} - P_{232} - P_{233} - P_{234} - P_{235} - P_{236} - P_{237} - P_{238} - P_{239} - P_{240} - P_{241} - P_{242} - P_{243} - P_{244} - P_{245} - P_{246} - P_{247} - P_{248} - P_{249} - P_{250} - P_{251} - P_{252} - P_{253} - P_{254} - P_{255} - P_{256} - P_{257} - P_{258} - P_{259} - P_{260} - P_{261} - P_{262} - P_{263} - P_{264} - P_{265} - P_{266} - P_{267} - P_{268} - P_{269} - P_{270} - P_{271} - P_{272} - P_{273} - P_{274} - P_{275} - P_{276} - P_{277} - P_{278} - P_{279} - P_{280} - P_{281} - P_{282} - P_{283} - P_{284} - P_{285} - P_{286} - P_{287} - P_{288} - P_{289} - P_{290} - P_{291} - P_{292} - P_{293} - P_{294} - P_{295} - P_{296} - P_{297} - P_{298} - P_{299} - P_{300} - P_{301} - P_{302} - P_{303} - P_{304} - P_{305} - P_{306} - P_{307} - P_{308} - P_{309} - P_{310} - P_{311} - P_{312} - P_{313} - P_{314} - P_{315} - P_{316} - P_{317} - P_{318} - P_{319} - P_{320} - P_{321} - P_{322} - P_{323} - P_{324} - P_{325} - P_{326} - P_{327} - P_{328} - P_{329} - P_{330} - P_{331} - P_{332} - P_{333} - P_{334} - P_{335} - P_{336} - P_{337} - P_{338} - P_{339} - P_{340} - P_{341} - P_{342} - P_{343} - P_{344} - P_{345} - P_{346} - P_{347} - P_{348} - P_{349} - P_{350} - P_{351} - P_{352} - P_{353} - P_{354} - P_{355} - P_{356} - P_{357} - P_{358} - P_{359} - P_{360} - P_{361} - P_{362} - P_{363} - P_{364} - P_{365} - P_{366} - P_{367} - P_{368} - P_{369} - P_{370} - P_{371} - P_{372} - P_{373} - P_{374} - P_{375} - P_{376} - P_{377} - P_{378} - P_{379} - P_{380} - P_{381} - P_{3

סיכומי יוג'ל אכונג - תצ'ין של פ' יואא מספר (צ'אור הכול)
הנכס / י' צא נ - פ'.

אבל אחי היינו רוצים אתה יתברך משלח אותנו צבאים חלשים

אתם מקרי - יש גאס שמעתי אצל (דואל) וישם ביתר
אקטאית אצק ותלם אלו וכן הלכה.

ההציה היא שסאונות יש dead-ends וזוהי תוצאה
 ארוכה מהן.



אז האט דאס האקראי געווען אז יחזל לעצור אלפונסצ'יק און
 באקאן. דא טעסטאנען שטאמענדיג פון שטענדיג אונקאמפלי-
 אדאציע - און אונזערע בעדלעך א שטוב, וועלכע אונזער פרויע
 און יענע פערטערע חזקא - און דאס אלע וועט אונזער
 געווען אונזערע שטענדיג און.

אשכנח וכו' יש מנהיג מועדים - המטמרים אהיה אתה
ג' לאתר נ' ע"י (ויק)

מסיבות של חברי כדור חושב את חצייתם זנים אפתי אצורה אשוא
לניאווה שבה נמצא פשוט אהם יש משמעותי הכמות הדפים

שיש ה - web, אז משתמשים ב-Power Method (32).
מתחילים מחישוב אקראי של u ומשתמשים בנקודות יור
של הנקודה כדי לעשות כמה איטרציות. התהליך הזה
מגיע לניווט האמיתי. בזמן פשוט רואים מספר קבוע
בשם של איטרציה.

הגדל מסה עם הקדקדקים יש אותו ציין!

אפשר לנסות לפרוק $page rank$ שבטח תראו נושא, ואם
מנסה תיפול לספורט. זה לא מתקדם אוטומטי -
 $page rank$ כי בציונים שלו אמסולדוסיים.
קוצם הגדל האקראי יהי לעשות סאפורטציה על צל. אז
במקום זה אפשר להגדיר את קבוצת הצפים שפשוט לעשות
אליהם סאפורטציה דהיינו יק צפים שאנחנו יוצאים להם
אינתיים לפרש שלנו. סתמים משתמשים בזה בלמוד
דהיינו נהג $spam$ ובעקרא $TrustRank$ למקבל
הסאפורטציה היא קבוצת צפים שאנחנו יוצאים להם $spam$

איק אפשר זהבוע פוחל על צל?

- ה - $TF-IDF$ - דברום באתר הרבה מילים שלנו
שלא צווק קלויות דאחר
- ה - $Page Rank$ - דייצ הרבה עינקים שמקלים למנו.

ע - לקחא מאחר ואננו על מלוא.

עוד כמה שיטות צירוף

- פופולריות הקדקדק - מספר הפעמים שמשתמשים אוהבים על
עינק בתוצאות החיפוש מייצג את הכלואות.
- $stickiness$ - אבדוק כמה זמן אשמש נמצא מאיזשהו
אתר - אמדוד כמה זמן. זמן עד שהמשתמש חזר לצל
תוצאות החפוש.

הם מקרה ב' הנסיון האלה סיבכו את עצמם -

rich get rich - מי שרבה יש לו

page rank גבוהה בנראה משקל גדול כי הרכה
מזאנו אולי ויקשנו אולי ואולי יתנו לו יותר קדימה.

XML

XML זה סגור קובץ עם tags ומכיל HTML
סימני XML אלא שב XML אפשר להוסיף tags
בשם שרצוה.

חשיבות

ההבנה של XML להמציא את ה- web הוא להיות סמנטי.
אפשר יהיה ליצור למשל אתרים ולא סתם
לחפש מילים. אז צריך למצוא דברים ולחבר אותם
חיוני. אבל זה הכל לא פשוט

- איך נוצר שהאתר מתאר את מה שצריך?

- איך נוצר איזה מידע זהו?

- דפים משתנים כל הזמן כי ישנן הרבה דפים

הקוד מתחבר.

את הדף הייתה מסד נתונים גדול הם היה צריך להחליט איך זה לא
הולך. אז יש שתי גישות

- בינה למאמרים

- להפוך את ה- web למסד נתונים - לפרט את כל

המידע ב- XML.

כאשר נחבר וישלח שנתמקד בה

כדי שמיונה תוכל לזכור
איך לא לא לכתוב אותי יחד עם הסמנטיקה שלו.

XML זה סינטקס שמעביר דתג לטקסט סמנטיקה (להזכיר
שם, שם, אופן, או מיל וכו')

RDF מאזיר אובייקטים וחסמים ביניהם.

XML מאזיר אקספוזיצה שמקלית מושגים ורעיונות שונים.

שירותי Web מאפשרים מאגרים עתידים איך אוטומטי
אנחנו נמקד באינטראקציה הכוללת.

יש ציוד הרבה XML בשיט כזוה של RSS.

34) 4/6/09
DB

בשילוח הקודם התחלנו לדבר על XML. אמרנו שהמטרה היא
היא semantic-web. web זה יהיה מובן לא רק
אנשים אלא גם מחשבים. וזה ההבדל בין XML
ל-HTML. HTML נותן לנו אפשרות רק על ה style
על הסקסס ולא על המסמך שלו.

לדוגמה מוסיפה היא החלפה מיצג. יש הרבה מקומות של מיצג
אבל ב אחד מסמכים שונים וגם סמכות שונות. למשל, יכולים
להיות מאגר מיצג של תכנות. ואם התכנות כולל להתאחד
בן כולל אינשיו לחיות את המיצג. איך זה עובד?
ב חסכה יכולה לעבור למטה ביניים XML ורק הן
יכולות להבין אחת את השניה.

XML מתאר כפי רובן לא style. למה זה טוב?
יכול להיות שניצור שם אתר ישגנה אם נכנסן או שאנחנו
העיצוב משתנה. אם האתר שלנו כתוב ב-HTML נצטרך
אז אם נרצה לשנות את המראה זה מסובך ועלול לשבש
את הסקסס. XML מסופק ליתר א-הסקסס הנפיר
באז המעצב הגרפי יכול להתאסן רק את העיצוב.
קובץ XSL לוקח XML ואומר איך להציג אותו.

- XML הוא למעשה מבנה פירמא של אמצעים שבצו
מחציתם אותו כעץ. עקיצה ציג של הוצף באותה דרך יש
סדר. לפעמים אפשר לעשות היצגות פנימיות לוקח הוצף
ואז נוצר את כליו.

- אגדים של XML יכולים להיות אטריבוטים (חמש) אפשר
לציין מה השם של הטקסט

- ערכים של XML מיוצגים יש בן שם

- XML הוא דגיש למסד נתונים case -

אם יש לנו טבלה אשר בקורותיה רשומים אותה - XML -
פשוט בל שיהיה בטבלה תיבה אלמנט ומתוכו תת-
אלמנטים שמכילים ערכים.

הכיוון השני קצת יותר קשה. קשים:

- איך יתכן להיפוך מספר פעמים (הנחיות) (מובן)
 - (הרציון) שבו בל אטריביוט בטבלה הוא ערך בלבד)
 - ערכי שדות יכולים להיות אטריביוטים שונים
 - וגם יוצר הרבה ערכי XML בטבלאות, אם עושים
- תרגומים:

- כמה טיפים מועילים למי שמעוניין

- הסבר הוא מיותר

DTD - Document Type Descriptor

זו שפה סגורה שבה אפשר להגדיר מה צורה רצויה במסמך

XML. אפשר להשתמש בזה כדי להגדיר שפה XML

מיוחדת לצרכים ספציפיים. ואז אם קולט תואם DTD

מסוים אז תוכנו שמכונה את ה-DTD הזה יכולה להיות

להבין באופן מלא את ה-XML

אם ה-DTD כותבים באמצעות סימנים רגילים.

קובץ המצגת - ספר טיפוסים.

תכונה חשובה של צורה רצויה - DTD היא 1-*unambiguity*

כלומר ניתן ב-*parsing* אנונימי ציבים לצורה באינה חלק

של הסימנים הנמצאים איתנו נמצאים.

למשל $(a, c) | (a, b)$ ואם מקיים את התכונה

אז $a, (b|c)$ מקיים את התכונה.

קובץ זה: יש ביטויים רגילים שבהם אין אפשרות להבחין

בצורה 1- חזרה מחדש. למשל $(a|b)^* a (a|b)$

אבל יש אי-אמיתות שמציינת את אפשרות, ואם כן, זוהי תוצאה.

35)

שפה רגולרית אפשר להציג באמצעות אוטומט
אנחנו נשתמש באוטומט מיוחד (קראו פשוט להלן)


למילים:

- 1) ניקח את המסלול היחיד e^+ - ee^*
- 2) מסלול של b המופיע של b אולי $a^*, (b|c)a^*$
 $\hookrightarrow a^*, (b|c)a, a^* \rightarrow a^*, (b|c)a_2, a_3^*$

זרעו אין אותיות שחוזרות על עצמן.


- 3) יוצרים מצב עם אותיות ממוחברות ועוד מצב q_0
- 4) המצבים המקבלים הם b המצבים למצבים אחרות למילה
 יכולה להסתיים בנקודה.

- 5) יוצרים מסלול ממצב q_0 ל- a_1 a_2 a_3 אם יש מילה שבה q_0
 נמצא אותיות li המופיעות הוא pr k
 בדומה לפני.



שפה היא $a^+b^+c^+$ - משמעות אולי האוטומט פשוט להלן
 הוא צטרף יחד!!

למשל, $(a,b|c)$ הופך ל-



ולכן
 "מיוסר"!!

ציון: (תבנית ב)

```
<!element country  
  (president | king | (king, queen) | queen) >  
<!element president (#PCDATA) >  
<!element king (#PCDATA) >  
<!element queen (#PCDATA) >
```

דוגמה: שם מדינה (king, queen) - מלך/מלכה

president | (king, queen?) | queen
(יש שפה ספירה שבה יש רק מלך)

ציון: אפשר לשלם באשראי ואתר כמזומן. אפשר

באשראי ומה שרובים ובמזומן עם (יותר עם אחר

חייבים לשלם. — cash | (card+, cash?)

המציג יש פירוט של הסכום של DTD ודוגמאות.

חסרונות של DTDs

- קשה לעבוד איתם parsing

- אי אפשר לעבוד איתם של "דוגמה" בתבניות - בונה

- אי אפשר לעבוד של אלמנטים שונים בתוך אותו אלמנט

- צריך מקום אקסטרנצ'אלי כדי לתאר את - a

יש שלושה בנים, a, b, c הם משנה באיזה סדר.

- צריך לכתוב האלמנט "הצורה" של אלמנט סופי

שאתם רוצים.

- ואז... (המציג)

ההבדל בין אלמנט לאטריות:

element

✓
x
✓

attribute

x
✓
x

הם אלמנטים
ID, IDREF
Entities

XPATH

XML שומר את המידע. אבל אנחנו צריכים דרך לשלוף את הנתונים מה XML. בשביל זה יש את XPath. פירוט של הספקים ופירוט נמצאים בהצגה.

נציג - דוגמה קטנה עם XPath (למה נאמרים על ה. spec) ומהבין את יחס ההבנה בין ביטויים.

XML Storage

אנחנו רוצים לחסוך את היקפים מאוזן יעילות ואז אופן שמירה המידע מתחיל להשתפר, בחיפוש של הביטויים אצלם יש סוגי הפעולות שסופגים פעולות ביניים.

יש שלושה יעשיות מקובלות -
קבצים - ב מסמך הוא קטן

- אחסון אינדיקס או המסמך אסוציאציה נעזרים רצות.
- Native XML Database - מסד נתונים שמאוחסן בצורה טבעית.

החיסרון המובהק של שימוש במסד נתונים רצות הוא שקשה להעביר את המידע ודיווחים אחרים. אבל מצד שני יש נכס תשתיות מוכנות וישנים של מיקוד ואופטימיזציה. הבעיה עם Native XML DB היא שכל תחום שעוצר את הפתח של קוד ויש אין אופיו מוצר מסתובב.

XML Storage

יש לנו את ה-XML הנדבר הזה, אבל איפה ואיך נשמור אותו?

יש מספר אסטרטגיות זיכרון למידע:

- קבצים - פשוט וסימפלי +
 - אינדיקס וטבלאות - למידע נגזרים רציפים
 - דאטאבאז - למידע מיוחד - XML
- אנחנו נסיר קצת מכלול - אסטרטגיה.

קבצים

בפעם ששמרנו שאלתנו צריך לעשות parsing של הקבצים. אין שום אינדיקס לעזרה. כל פעם צריך לעשות parsing מחדש. יש שני סוגים סטנדרטיים של XML-parsers

- DOM - אינדיקס מלא (מחזיק את כל ה-DOM)
- SAX - דאמיין את המידע הנדרש בלבד

DOM - אינדיקס מלא. איך עונים על שאלות?

- transaction/buy - ביזק'ים אם השורה הזו

transaction ואם לא ביזק'ים אז לא

buy (אין) תצטרך לעשות parsing של ה-DOM

- ticker - אינדיקס מלא של ה-DOM ומתפזר

אם ה- ticker מתפזר

יכולים - די טבעי וקל לשימוש

- אפילו פשוט parsing פה את כל האינדיקס

כל הדרך לעלות

מסקנה: - צורך הרבה מאוד זיכרון כי ה-DOM של ה-DOM יהיה בביזק'ים והוא

זאגט אזוי בעיקר כי ב-טמא ויש איזו (ס"ה)
ל"זיגט מסמכים אמש (עק"ם) של אמת MB ואז
גענוג מתחילת עקרוס...

- צוויק לעבונ אן ע המסמך לפני לשלש לענוג אן
שלימאן ע"ש, אמ השורש ע"ה היה transaction
מסמך היה לקרא קצת מהקובץ כדי להבין לשלימאן
דוקה.

- SAX - עובר ען המסמך פעם אחת ומודע ען פעם לקרא
חאב מלפני מענין. איך ענים ען שלימאן?
- buy/transaction/ - אודאים של event פראשן
הוא transaction ואז עקבים עד לעוד עשב
יק שלצדיק עקבים אחי הכמה לענוגו נמצאים בה
- בעצמ יש הרכה book keeping ע"ש - ואז עקבים
אחרי צו מסמך הכפורה זה לא מסוד מסמך.
מכונה - לא צויר הכמה סיכון, אהר
מסונג - אי אפש לקרא מתורג

מסד נתונים רצאני

הק שים העיקריים הוא בתרגום ה-טמא עטמאל
ואז בתרגום (שלימאן) ע - טמא.
DDO יורא לעבונ מסוד מוכב טאב בעיה יתר קלא הוא שטמא
יש שני ממצא ואין ב-טמא יורא לעבונ קיטן בעמך בע"ה אודא.
חלף מוכ ב-טמא יורא לעבונ ערבים מרובים עמא attribute
וכן יורא לעבונ קורסיב.

אפציה 1 - אין אן DDO

נשאיר אר מבנה העץ הולק הטמא. ע"ה קוצקוז (ע"ה) אן יורא,
נשאיר ע"ה אר הסוג והעקב ואז טמא שלו. יק אפש לשלש
אר מבנה העץ. פראמה במצאה נכבד למסמך טמא


```

< book >
  < title > ... < /title >
  < author >
    < first name > ... < /first name >
    < last name > ... < /last name >
  < /author >
  < address >
    < city > ... < /city >
    < country > ... < /country >
  < /address >
< /book >

```

SC אפשר להסתפק בסמל של מחזור
 title, first name, lastname, city, country
 זה נותן את כל המידע הדרוש אבל איתנו נאמרים
 את מותג הקופא. אז אם נרצים גם לשמור את ה-XML
 צריך לשמור מידע על המבנה שלו.

בפנימי DTD הוא קובץ אינסטיי XML חזרתיים איתנו.
 האם הוא אכן בפנימי DTD למצוא סכמה בלתי-
 שיחיה עוזרת של מסמך XML למחשבים - DTD.
 DTD-ים ונתונים אלה מאוד מסובכים. עם קצת עזרים תהליך
 פישוט - D2 פישוט של D. אם של מסמך לתואם את
 D, הוא גם כמסמך תואם את D2. (כמעט) בודקו תואם את
 נדוי סדר הבנים.

תקני פישוט:

$$(e_1, e_2)^* \rightarrow e_1^*, e_2^*$$

$$e_1^{**} \rightarrow e_1^*$$

$$(e_1, e_2)? \rightarrow e_1?, e_2?$$

$$e_1^{*?} \rightarrow e_1^*$$

$$(e_1 | e_2) \rightarrow e_1?, e_2?$$

$$e_1^{? *} \rightarrow e_1^*$$

$$e_1^{??} \rightarrow e_1?$$

$$e_1^+ \rightarrow e_1^*$$

... וכו'

29

נאמרה בחקי הפישוט היא מצאם למחוק יורה רק
אופת אצ של פ אצאנץ ושל יורי סאצוים אצצוים
אסאכניס אצניס...

2N613

$$(b|c|e) \text{ ? } , (e^2|f^+)$$

→ $(b^2, c^2, e^2) ? , e^{??}, f_t ?$

→ b??, c??, e??, e??, f??

→ b??, c??, e??, e??, f+?

→ b^2, c^2, e^2, e^2, f^2

$$\rightarrow b^2, c^2, e^*, f^*$$

איש או אשה אשר יהיו חתנים או נשואים
ועל ידיהם יבא להם ילד יבא ילד זה יבא ילד זה

$$(b|c|e)^2, (e^2|(f^2, (b,b)^*)^*)^*$$

→ b^*, c^*, e^*, f^*

אברהם ענשים רב הגדלה של אלאנס ב DTD .
אבל ע"כ גדל - DTD .

הקיצוניים הם, אמנם, אטריות ואפרכות (2, x)
 כל אלה מופיעים גם אחר אטריות מופיעים חסר
 נמצאים להם מופיעים - ID.

אברהם בן יצחק אבן עזרא . ספר חסדיו

זכור לך 3/7 3/7 אלא

אם נכח נכנסה 6) כי אין צורך לעסוק

(15 83'N)

אם ציגלונס ס'עפנטער 2 (כ"ב) פ'ק'א'A' -

(83'N) - 1/2 1/2 m'ed

ענין חסד וחסד וחסד * (כ"ו) חסד וחסד וחסד

החתי מורדא על הארץ בשונה של (לחל)

From Irene 3/23/7 -

יגיונות לעומת האופציה הקופאה

- הרבה יותר יעיל עבור שאילתות מסוימות כמו של משלוח ושל פרוסי של טהם מסמך - צריך פחות חוסן מין
- סבסאט והסבסאט הם קטנים יותר
- יותר אשליה כמו "ל הכתובים שלם Jack" - לא צריך לעבוד על הנתונים שלם רק על סבסאט אחד
- מסכנות
- צדין יש שלוח של צדיק אשר בשבילן הרבה חוסן-ים

הערה:

- האם כדאי להשתמש באפשרות צדים כדי לקבל בין ילדים ערבים? אולי היינו רוצים את זה בעתיד אבל כרגע יתאים לרבות כמה הורים ואין לנו צורך להשיג למפתח שלם (מלאו בעצמנו סבסאט אחד) צריך ערבי באיזה סבסאט מצויק של צדיק אפילו.

אופציה 3 -

- צומח קשיחה הקצומה את החקוק עיצוב הסבסאט קרה
- שנים - פחות במצגת. השיטה היא מאסיבית
- מספר הצדדים של צדיק שלם. לעומת זאת ערבים נוצר צורך בשליחת אומדן כי מידע יתאם אפילו בין כמה סבסאט.

אצו (תוכנים מיוחדים) - XML

- הרעיון הבסיסי הוא לשלוח את המסמך כחץ והכעיה האנוכית
- היא יצירה שיטה יעילה לענות על שאילתות.

המחלקה עובד במסוקים וכל מנסים לשמור באה שיותר
קוצק (צד קרוב) הוקר אותו המסוק. אנתוני לא (תמקד)
המסוק של הסיוע על הצדק עמדה של עובד -
מתנייה על הנושא הזה.

אינדוקס - נצטט על שמו אוסטרליה.

- רשימה של אמצעים ועכשם -

רשימה של סוגי אינדוקס -

value - על צד שמות בלי יש רשימה קוצק (צד)

למחלקה

element - על אמצעים (שם של אמצעים) שמות

בלי רשימה רשימה של קוצק (צד) עמדה אמצעים

המחלקה

אם הרשימה האלה נחשב אפשר לזכור גישה למחלקה

אם אנתוני לא (תמקד) הזה

structure - עמדה אוטומוטית ספציה - על הקוצק (צד)

המחלקה (עמדה) עמדה של אמצעים (פוזר)

עמדה

עמדה של אנו נק element, value. אנו עמדה על

עמדה // buy // exch ? שם אמצעים:

- עמדה buy ואמצעים עמדה

- עמדה exch ואמצעים עמדה

אם יתכן? נחשב על תלוי בתחילת הספציה אנו

העמדה אוסטרליה השניה יש עמדה אוסטרליה

הם שלם רשימה (תלוי) יפוט (עמדה) אמצעים, אנו

המחלקה (תלוי) היא עמדה

אנו עמדה, אנו buy עמדה (עמדה) exch אנו

אנו עמדה עמדה אנו קוצק.

האמה היא ששתי האסטרטגיות האלה זרות כל אחת מהשנייה
בניקוד אחרות של גודל, אבל הדבר הוא הדבר מאוזן ואולי
לא נכנס לזיכרון הראשי.

עם נכרה לעזרה של האלגוריתם רק בזכות האנדרסון.
בשלב זה נעשה קריאה ראשונית של שורשים באינדקס.
עם זאת נשמר שלש (start, end, level)
דבר שאפשר לנו לעבור קיטון. ואזבא לקראתנו נוכל
ש לקראתנו אתה.

מטרה: לעזור של האלגוריתם מהצורה מ/מ
אנטיאלי: אחרת - DFS על אפס זכר
הצמחונים וקשיים במחשבה שלב זה היותר
מקרה השל. המחשבה מייצגת יחס של אב-קצוות -
צאצא.

תשלום לשיעור ביום -
- הכנה להקדמה (a|b), b, (a|b)²
לא תזמנה כי אם מתקבלת ב-b לא בנו
אם זה הראשון או השני מהביטוי.
אחר של זה מציין שפה סופית בכוח אם שיש ביטוי
אז משמתי לקהל:

$$((a|b, b, (a|b)?) | c) | (a|b, b, (a|b)?)$$

האסטרטגיה המקרה הבסיסי היא לחלק את המילים לחלקים
זרים שאינם תוספת אשלמית.

- /*/* לקול א - /*/* וגם לניהם אחזרים את
ב הקראות שלבים השונים.

- /* המילים של הביטויים הקצומים והמילים רק את השנים
- /* אחזרים את הקראות.

4

- $[a][a/a][a] * //$

אם מתקבלים מהתנאים הקצקלרים שצריך להתחבר
 הם $a //$ *

התנאי הראשון אומר שיש לשנות צאצא a סוף
 אפילו להתקבל מצה כי בלאו הכי אנחנו צורשים
 $a //$ * וכל מה שמקיים את זה רבוי ברוב
 מחנו שיש לשנות צאצא a .

התנאי $[a]$ צורש שהשני של הצף הוא a .
 סבב זה מחזיר קצקלרי a שנהצאים בל מקום
 ביכ לשנות שיש להם צאצא a וכן אם
 השנה של הצף a

ש"ב - כך חלק א'

1. The first part of the paper is devoted to the study of the

2. The second part of the paper is devoted to the study of the

3. The third part of the paper is devoted to the study of the

4. The fourth part of the paper is devoted to the study of the

5. The fifth part of the paper is devoted to the study of the

6. The sixth part of the paper is devoted to the study of the

7. The seventh part of the paper is devoted to the study of the

8. The eighth part of the paper is devoted to the study of the

9. The ninth part of the paper is devoted to the study of the

10. The tenth part of the paper is devoted to the study of the

11. The eleventh part of the paper is devoted to the study of the

12. The twelfth part of the paper is devoted to the study of the

13. The thirteenth part of the paper is devoted to the study of the

14. The fourteenth part of the paper is devoted to the study of the

15. The fifteenth part of the paper is devoted to the study of the

16. The sixteenth part of the paper is devoted to the study of the

17. The seventeenth part of the paper is devoted to the study of the

18. The eighteenth part of the paper is devoted to the study of the

19. The nineteenth part of the paper is devoted to the study of the

20. The twentieth part of the paper is devoted to the study of the

(42) 18/6/09

DB

DB
6F
המסמכים

שבת שעה זכרנו בעמוד המסמך:

ההנחה של labels כזינו למצא שאור קצקזים שמקיימים קשר אב-קצמון - צאצא או אב-בן.

נבחר שלב label יש לנו רשימה מחינה של קצקזים אם ה- label נזה. האינטואיציה היא שאם נעבור על הרף ה- DFS אז המחסניות תגיע לב היות שרצואה הרף וקשר אב-קצמון - צאצא מתבטא בכך שהאב הקצמון מוכנס למחסנית לפני הצאצא. אז אנתנו חוזים לסמלף מצב על הרף ע"י מצב על האינדיקס.

באתר מאמר שמציג את האלגוריתם הזה יש גם גרסה של האלגוריתם שמחזיק תוצאות בצורה מחויינת לפי האב הקצמון. זה עוזר למשל אם חוזים לחשב את $a // b$ אם אפס של חשב את $a // b$ ואז ננסה לחבר אותו ל- c . השבול זה צריך להרשימה $c // *$ תפיה מחויינת לפי האב של c ואילו מחשבים את $a // b$ ואת $a // b$ אז צריך ש- $a // *$ תהיה מחויינת לפי הבן של a . אז בקיצור, שני הכיוונים של הסיצור חשובים ומי שנוצה יכול להסתכל במאמר. המצגת אפס למצוא את האלגוריתם שמחזיק לפני צאצא ואב לפי אב קצמון.

נאם אפס להשתמש באלגוריתם דומה כדי לחשב ציונים אחרים? עברו יחס אב-בן זה מאוד פשוט לשנות את האלגוריתם בהתאם. following זה קצת יותר מורכב... אבל אפשר (הייתה על זה פעם שאלה במבחן).

כמוכן, רפוזיטור של $Path$ שלמה זה מאוזן
פשיט להיותים. מתשבים זה ואז מוחסום אלו (כח)
שאמתו קדם $a//b//c$ (

ל"ה - האם אפס רעשו אצפס ציה) אפסיותם
כאש ה- XML הוא גרל אפס (רשים
ע"מס ה- IDREF

אחמאי XML יש נט"ה למסנה שחור $a//b//c$
ואת זה אפס אנצפס רפוזיטור ביחוסיות אור
המסמך אפס אפס $dataguide$
נתמקד כזה בלמיתור מסול - אפוקר אפצורה
 $a//b//c//d//...$

ה- $dataguide$ ב קאנקר הוא אפס אינדקס
מאצמז ל"ה הקאנקרדים המתאיימז בגרל הקצום
ואז רפוזיטור אפס לחפס אתהמסדוס בגרל
הקטן ואז הקאנקרדים שנמצא בו נמנים ל"ה אור
התאצמז אפס אפוקר הקצום

פוזמסור:
אפס X אחמק XML נאמר ש- D הוא $dataguide$
ל X אפס:
- ב מסול ל $labels$ ה- X אפס בקצוק פופ
אמת ה- D .
- ב מסול ל $labels$ שחפס ה- D אפס
לפחות אמת ה- X .
* מסול אמתותו גרל אמת בשמש

(43)

נניח X מסוג XML. D - dataguide
יהיו p, p' שני מסלולים

מסלול p - $p(x)$ אולי קבוצה (בדק, ציטוט) של
אלמנטים ב- X כאשר הולכים על ה- D מסלול p .

נאמר - $p \equiv x p'$ אם $p(x) = p'(x)$.
זה אומר ש- X או אולי אולי תהיה בין p ו- p' .

נאמר ש- D הוא dataguide חזק X - D אם
כל שני מסלולים p, p' אם $p \equiv x p'$ אז $p \equiv p'$.

$p \equiv p'$ ואם $p \equiv p'$ אז $p \equiv x p'$.



זה אומר ש- D חד-משמעי במובן של האלמנטים הציטוט
הציטוט של x זה $p(x)$.

דוגמה: dataguide חזק, אבל לא D חזק.
(מחזיקי). אבל אם X הוא XML ו- p הוא ציטוט

המקסימלי יכולה להיות במובן של x .

המחזיק חזק D אומר ש- D חזק.

דוגמה:



$(1,1), (2,2), (3,3), (4,4), (5,5), (6,6)$

$p = \{(A,2), (A,4), (B,6)\}$

$A: t_2 = \{2,4\}$ קבוצה של מסלולים

Recursive Make $(1,2,4, b)$
 $p = \{(C,3), (C,5)\}$
 $C: t_2 = \{3,5\}$ קבוצה של מסלולים

44

Recurring
make

$$p = \{C, 5\}$$

c: $t_2 = 453$

hash 70K
710 3315 K
e

תסבירנה:

הנהגת עמל נכסיו -

- אמתים זקוקות

מכונות: אם ה- dataguide מכיל את (כנס לסיכרון את
זה מאקד יחס (ולא גממה שקורה בלד כי XML הוא חלק
לר את המון תצורה)

ל"ב - א"ב strong data guide
 אחר דאמא א לאוהא למקרא תשובה א (כונה
 בש"מנוס כו.

2

XML টার্মিনোলজি



זיוק ראשון לאנשים (ללא) שאיור בשפה יותר ברורה -
 keyword search (סמני כניאה לא מבקש לדלותו)
 XPath

הנה ציור פסיקה ארגונית חופש מולת מפתח - זו רשימה של מונחים
אחפוש של יחידים אריות מ-3 צורות

author: smith : p181 label -

: Smith : 28 -

author: : label -

1000

- להבין מה להחזיר למשתמש. כ- למד כנראה הכוונה היא
- אצה תהליך מתקדם לשלילה. למשל, אפשר להחזיר את תר
- החלף המינימלי שמוזר או מונחי החידוש.
- להימנע מההחזיר אומנטיס שאין להם שום קשר אחד לשני.
- בשטח זה צריך לנהל צורה המשתמשים מתכוון...
- איך מעשית צורה של התוצאות - כי בעצם פתוחה לחלוטין זה
- ביום והבציר הוא שאין מספיק מסמכי למד כדי לעשות user study
- להתחיל איצו שיטה במה אברה.

X Rank

שאלות הן אלו חסות כמו סמנים חסותיים.
תוצאה של שאלות הן חלקים של AMC שאלות אחר
של אלו החסות והכי קטנים שיכולים להיות.

כך - HTML נותנים דיווחים על מסמך. ט - XML (נרצה להתעקש)
על אפוא. אז הרעיון (הוא להרחיב את שיטות הדיווח
שאתנו מכירים, רק לשלב וזהו) אולי XML

אם רוצים לקחת מחשבון?

- אינקיפּטין רכבים
- קרבה בין אטומים
- אנתוני (תחמד) בדירוג לפי אינקים.
- אצף אינקים של מונומק מלמ ?
- אב של מצבים זמן
- בן של מצבים זמן
- קלפי IDREF
- קלפי XLINK (הכבדות מונומק מלמ אתר)

PageRank - 13 ביטויים

יש הרבה של מסמכי מאג. ס' למנוע מחסום הוא קונצקציה.
הצדדים מייצגים דרכים לעבור בין אלמנטים - אבל, כן, לא, hyperlinks או רנדומליזציה לקפוץ.
וזהו מתקנה נוספת דומה לנוסחה של Page Rank

השלכות:

- נניח שיש מסמך שיש לו מספר חלקים של דרכים רפרנסים.
- אז כל שיש יותר רפרנסים החשיבות של חלק יורדת.
- אז זה אפשרי לחקן ע"י שנסתב על עינקים חיצוניים.
- עינקים מבנים אחרת וניתן להם הסתברות שונה.
- למעשה, אולי זה נכונה להתייחס לעינקים אלה כן בשונה מעינקים של בן-אב.

- כמוכן, אפשר לתת לזה אינטרפרטציה של חלוקה מקרה.
- Page Rank של אלמנט e הוא ההסתברות שנגיע ל-e אם נתחיל בקונצקציה מקרהי ואז
 - בהסתברות $d_1, d_2, \dots, d_n$ (קפצו לקונצקציה אקראית)
 - בהסתברות d_1 נעבור אליו, חיצוני
 - בהסתברות d_2 נעבור לבן
 - בהסתברות d_3 נעבור לאב

האם השיטה היא האופטימלית?

- נניח ש-IDREFS מתבנים מסומנים למאמרים שלהם
- מציגים. נראה כי סביר שאם אישהו חשבו מצטט אותך אז זה אתה חשוב.

- IDREFS מתבנים צורה נקייה עם המחלקה שלהם - איש נקיין חשוב אם המחלקה שלו חשובה ולדפוק - זה יהיה מתחיל להיות חפץ.

- IDREFS מתבנים ארצות עם מדינות שונות. אז מדינה גשומה אולי היא אופטית בהרבה מדינות חלשות. ומה עם אוסטרליה?

אינדקס

נוצרים להחזיר את האלמנטים הכי ספציפיים עבור מילות חיפוש בלבד.

שיטה נאיבית היא להתייחס עם אלמנטים בקבוצה לעשות
inverted index (ראו). הבחירה כאן היא שזה תופס זמן
מקום אבל מחזיר עצה סתם חושב ושימוש לא מאפשר
להחזיר את האלמנטים היחידים ספציפיים.

Dewey Encoding - אפשרות לקידודים עבור
נקודות A הוא אקדמון של B אחר
המספר של A הוא prefix של המספר של B

46

DB

מה שלא נספח ואמר מה שקפ"ם לא י"ל בחומר אבות

2

XML (PN) key word search: 60 01203N 11011E

11/12/14

- איך אפחיל אה אפחיל אפחיל?

- איך צדק את התוצאה?

۱۰۱۰

- קרבן (זכר) ח ית שש (וריד א-ח) אה הצאצאים של

שמעתי את ב' אלוהי האמת, ה' צדק ויניח את ב' אלוהי

המחבר

XML - (סמלית) PageRank - מחשוב קישורים

היום נאמך איך אמר אגב הקורקאזים הרומנים מזרח מזרח

כמוכן אצלנו נכנסה רחל בת שבע ויהיה חלל (חמד)

אם נצאק אפארקו קאן דא פאס אהר.

מסמך - Dewey Encoding

את ה-nodes כולו רק שניתן להם את ה-headers וחוסים

על ידי ה' אלהים בן הקדושים - כזכר -

68 inverted index הק/הקצוים וזחרי עכר חגור

2011

אשר אלהים אנון לעולם ואלהים אלהים אנון לעולם

[illegible]

המזכיר יש פסאידו קוד (לאחרים) שאלו את הסמל
קצורה יעלה.

המשק החצונה מה מצב:

dewey ID	XQL	language	all
1	✓		
2	✗	✗	✗
3			
4	✗	✗	✗
0			
47			

אתנו שאתנו ש- 47.0.2.0 חקיים את מה שצריך
אתנו וציעים ל- 47.0.1 והתחילים המשתמש הארכה
ביותר היא 47.0 חק מוחקים את השורה
של 0.2.0 ומכניסים שורה ל- 1 וממלאים רק שורה
אחר את 47.0.2.0

13K 13K 13K

השיטה הראשונה היא שימוש בשרתים אחדים
- Path ובהם את כל הנתונים שיש להם
המחנה של הקובץ ואז אחרי ההקמה השלישית
- XML. זהו סוג של נתונים המיועד
לדואר - Web. זהו סוג של נתונים המיועד
של המערכת והוא אחראי על כל הנתונים
שונים של המערכת כגון Scalable. את כל הנתונים
שנדרשים לשרתים של המערכת
בניקוד של המערכת אחת של המערכת - query
processor. זהו סוג של נתונים המיועד

יש הרבה מחקר בנושא ויש המון הערות ואיזורים שונים.

אבל יש כמה מספיקים משתנים.

- להרשט של חוק מחקר קבוצים בשאלות לא תהיה התאמה

- להרשט אסוף בשאלות להתאים (למשל מקום חופש

הנים אפשר חופש צאצאים)

- חופש להתאים קבוצים עם משמעות דומה (למשל film

השאלות לעומת movie - למא).

אנחנו נמצא מאר ספציה (שמו במצב).

שאלות היא למטה חץ. המאמר מאפשר אומץ סוגי הקלות

ל חץ השאלות.

- הכלל קבוצים - אם יש לנו איזה אונטיות ויש לנו איזה

ל יחס type / super-type ואם אפשר להחליף

קבוצה בשאלות בקבוצה אולם יותר

- מחיקה של מה חץ (ובצד שנקבע לתוס

- החלפת יחס אם-כן ביחס אם קצוות - צאצא

- קידום תת חץ - לקחת כן להפוך אותו לכן של הסמל

אם ההקלות האלה אפשר לשרשר בהם מני צבים

אל תשובה משוערת היא תשובה מדויקת להקלה שלי

השאלות. אבל לא בהקלות אומות האותה איזה. אך

זה קבוצה אם צד יש שני צינים - למקרה שותלובה

מדויקת למקרה שותלובה משוערת. רק אם תשובה אפשר

חת ציון להחליט מה יותר טוב. את הצינים ניתן להשתמש.

שיש נאומות אומות אתם ההקלות, עם אחת לחשב את

הציון ולהחליט את הטובה ביותר.

זו זכרון הסתמך במקרה שהמסמך והשאלות הם על.
כזה דבר נכון במסמך שהמסמך נק - node deletion
אולם מה המסמך והשאלות יהיה אלוהי על - זהו מכון
אתה עם שורה.

שאלות (יותר אלוהים, השפיע מדויקתם חיים) והתקיים
- אלוהי שורה - שורה השאלות חיים אלוהי שורה הגר
- אלוהי על - יחס אב-בן שחיים והתקיים
השפה הגרפית לה נקרא Subgraph isomorphism
שורה משהם שורה וזה מתאמה על.

אנחנו נרצה לאפשר את תלמוד חלקי - אישיות שנתונים
אתה מהערכים null, אבל צריך לעזור ארצה בצורה
האיווה וסביבה.

השפיע לה יש אלוהי ישירות - לא משהם צרכים סתם
הצורה תלוש מהמציאות. אפשר לעזור קצת ו (אובייקט)
ס אם יש משהם מהשורה של השאלות ו רק של
אלוהי הצורה ה המסלול מסופקים.

תשובה חלקי היא מסמך AND אם אלוהי השורה מסמך
ואלוהי ישירות מקיים על קצת השאלות שמשהם קצת
המסמך נקרא. כאן, אם קצת משהם אז משהם הצורה
הנכונה של צורה אלוהי משהם. - אלוהי אלוהי הנכונים
של.


בצורה מסופקת חלק אם היא מסופקת או שאתה או יותר
הקצת של משהם - null.
חיים חלקי הוא אישיות חלק אם השורה מסופק, אלוהי הנכונה
מקיים על קצת משהם וזה שאלות מסופק חלק.

49

תשובה חלקית בא OR... אם היא מספקת את
אילו השנים ואילו הנגשים.
אנחנו חצים לתת את אצד (הנצח) (אחר למיני הוא)
מקטעם אצד קיים מיני אחר למחל אלו ונתנו תשובה
לשאלת אנו נחש לך מיניים מקטעים.

תשובה אלה

- ① ואנו איך להשתמש באצד למחשור ב- DFS רבו אצד
יחס של קצקד-צא. האם אצד אחרים שא בקלות אצד
של גול בלי וואץ. האינסואיציה היא ללא נג האלמנטים
מחשור של זה אצד אצד נק שיתרופסיק יחס
קצקד-צא. זה לא אפשרי בגול בלי.
יש גם מחקרים להתקיים מיומנים רק מינים אצד אצד
② צדק אצד strong data guide אצד נתן.



1. /movie [year] /title [title] (מבוקש: תוצאות)

2. /movie [year] /title [title] (מבוקש: תוצאות)
3. /movie [year] /title [title] (מבוקש: תוצאות)
4. /movie [year] /title [title] (מבוקש: תוצאות)

4. /movie [year] /title [title] (מבוקש: תוצאות)

5. /movie [year] /title [title] (מבוקש: תוצאות)
6. /movie [year] /title [title] (מבוקש: תוצאות)
7. /movie [year] /title [title] (מבוקש: תוצאות)
8. /movie [year] /title [title] (מבוקש: תוצאות)
9. /movie [year] /title [title] (מבוקש: תוצאות)
10. /movie [year] /title [title] (מבוקש: תוצאות)

