

Posudek diplomové práce

předložené na Matematicko-fyzikální fakultě
Univerzity Karlovy v Praze

Autor/ka: Ladislav Peška

Název práce: Uživatelské preference v prostředí prodejních webů

Rok odevzdání: 2010

Autor v práci popisuje problematiku doporučování objektů v prodejních webech. V prvních kapitolách rozebírá problematiku a již existující práce na dané téma, poté navrhuje komponentu pro začlenění do existujících prodejních webů. Po uživatelské a programátorské dokumentaci je sekce experimentů a po ní již následuje závěr s možnými dalšími směry výzkumu.

Práce je napsána poměrně čtivě, formulace jsou jasné, zejména také oceňuji pouze ojedinělé překlepy a gramatické chyby. Text názorně doplňují i přehledné obrázky.

Vlastní návrh komponenty vychází z již existujících řešení, což je spíše plus. Vlastní kód je napsán pěkně strukturovaně, s komentáři (některé občas zůstaly ve formě zakomentovaného textu) jak před metodami, tak i v průběhu před delšími kusy kódu.

Silná stránka této práce je provedení experimentů na reálně provozovaných stránkách. Výsledky sice nejsou stoprocentně přesvědčivé, nicméně alespoň ukazují na další směry možného zlepšení. Oceňuji extenzivní přístup, kdy bylo testováno více kritérií a také dobré odůvodnění, proč zrovna tato kritéria jsou důležitá.

Kritické poznámky k práci:

Googlebot používá javascript, takže by se mohl tvářit jako uživatel. Nicméně podle DNS se lehce pozná, že jde o robota.

3.7.2. Čas na stránce, počet událostí a objednávky byly normalizovány do intervalu $[0,1]$. Chybí popis, jak to bylo děláno – pro každého uživatele zvlášť nebo pro všechny najednou? $1=$ maximální čas na stránce pro daného uživatele nebo přes všechny uživatele?

Vzorec pro StandardObjectSimilarity nedává moc smysl

$$\text{StandardObjectSimilarity}(o, o_i) = \text{Rating}(U, o) * \text{Rating}(U, o_i)$$

V případě dvou málo preferovaných objektů ($R(o)=0.1$) vrátí 0.01. Přitom oba objekty jsou málo preferované, tedy podobné. Lepší je PearsonCorrelation nebo NRMSE, která pro dva špatně hodnocené objekty vrátí vysokou hodnotu.

Výsledek experimentů na antikvariátu vyšel nejlépe pro Collaborative – sekce 7.5.1. Ovšem v sekci 7.4.1 autor píše o tom, že antikvariát měl malou návštěvnost a jinde v práci je zmíněn fakt, že antikvariát má velký poměr počtu objektů k počtu uživatelů. Jak si vysvětluje, že přes malou návštěvnost a velký počet objektů se kolaborativní filtrování vyplatilo?

Parsování SQL by šlo určitě zlepšit. Co se stane na parsování dotazu „select a as ‘where ‘from t‘“? Které where bude identifikováno jako where klauzule? Doporučoval bych použít nějaké robustnější řešení, např. <http://code.google.com/p/php-sql-parser/>

Není možné, že průběh experimentu ovlivnila také roční doba? Zejména na slantour, kde nejdříve běželo dummy a až poté bylo puštěno kolaborativní filtrování. Nešlo by použít data např. z loňského roku pro srovnání?

Poslední výtka patří k nastavení experimentu, kdy se metody střídaly sekvenčně za sebou a mohly být tedy náchylné na čas – např. o víkendu se mohou uživatelé chovat jinak než v pracovní den, nebo výše zmíněná sezónní závislost. Lepší přístup by byl náhodně vybrat metodu a tu použít pro daného uživatele.

Celkově se mi práce, přes řadu výtek, líbila a doporučuji ji k obhajobě.

Datum: 19.1.2011

Podpis: