

Recoll/Xapian - effiziente Dokumenten- / Desktopsuche

Michael Schwipps

26. Januar 2016

Übersicht

- ▶ Recoll ist ein Google für zu hause
- ▶ Motivation / Warum?
- ▶ Features
- ▶ Erweiterungsmöglichkeiten und Grenzen

Motivation, Eigenschaften klassischer Unix-Tools

- ▶ Unix-Tool: Xgrep, ctags, cscope
- ▶ zuverlässig, stabil, sicher, schnell – aber
- ▶ nur textbasierte Dateiformate, keine Binärformate
- ▶ RegEx, boolesche Verknüpfung über etwas Shell-Magie
- ▶ sehr gute Vim-Integration

Recoll

- ▶ Unterstützt direkt die üblichen Dokumenten- und Containerformate
- ▶ Container „multilevel“, z.B. tgz in Email
- ▶ boolesche Ausdrücke in der üblichen Suchmaschinen-Notation, Wildcard*
- ▶ die Textextraktion erfolgt mit Linux-Standardtools(z.B. pdftotext)
- ▶ leicht erweiterbar
- ▶ fuzzy-Suche, mehrsprachiges Stemming während der Suche (z.B. deutsch und englisch), Stammformbildung: fliegen, fliege, flog
- ▶ Priorisierung/Ranking
- ▶ aspell-basiertes „Meinten Sie“-Feature / Anti-Tippfehlervorschlag

Recoll 2, Xapian

- ▶ gibt's fertig als CLI-Tool und X-Programm
- ▶ Integration in Web-Tools (z.B. MediaWiki, redmine) häufig leicht durch fertig Plugins möglich
- ▶ Datenbank-Indizierung via Sprachintegration python, php
- ▶ Indizierungstrigger erfolgt über expliziten Aufruf (z.B. cronjob) oder via FAM/inotify

- ▶ Xapian ist das Speicher-Backend (Search Engine Library)
- ▶ in C++ geschrieben und mit noch mehr Sprachbindung für Perl, Python, PHP, Java, Tcl, C#, Ruby, Lua, Erlang and Node.js
- ▶ Indizierung via Recoll und Suche via Xapian möglich

Erweiterbarkeit bei der Textextraktion

- ▶ Beispiel: vermailte Pdf-Dateien aus einem Kopierer indizieren
- ▶ Besonderheit dabei: der Textinhalt steht nicht unmittelbar in der Datei
- ▶ OCR/Tesseract-Integration (Idee/Bug/Issue von mir)
- ▶ Anhänge kann kein (mir) bekannte MUA durchsuchen, der IMAP-Standard kann das imho auch nicht
- ▶ Container mbox / Email auf

Integration in mutt

- ▶ Voraussetzung: Speicherung der Email in Maildir
- ▶ Indizierung erfolgt wie üblich
- ▶ Suche über ein Shellskript das eine Maildir mit gesymlinkten Suchergebnissen generiert

Querverweise auf vergleichbare Tools

- ▶ Solr (fett, nur Web-Interface, Erweiterbarkeit nur mit java?), hat dafür noch weitere fuzzy-Methoden (z.B. Levenshtein) und ist clusterfähig, skaliert besser

Fragen und Quellen

- ▶ Fragen?
- ▶ <http://www.lesbonscomptes.com/recoll>
- ▶ <http://xapian.org>