manpages.debian.org

GPN17
Michael Stapelberg
<stapelberg@debian.org>

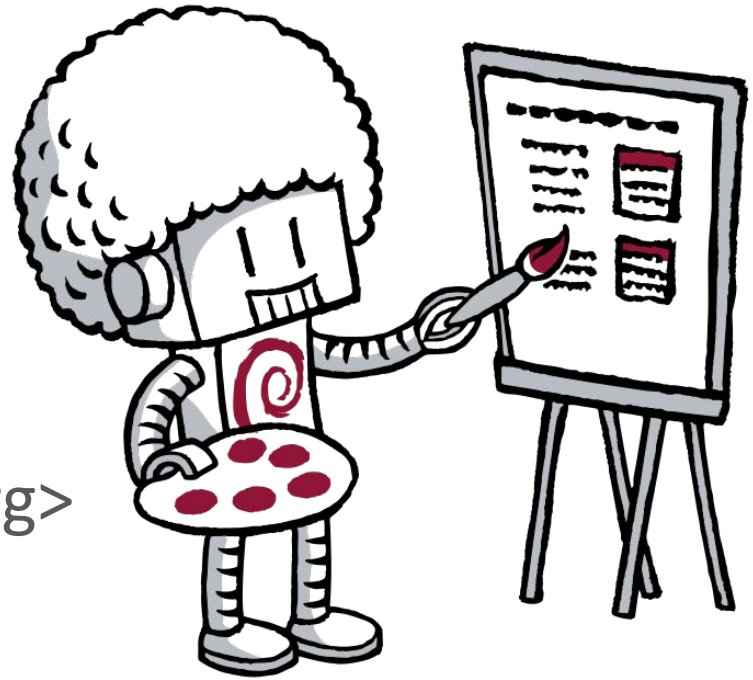

Agenda

- Motivation
- Übersicht
  - manpages extrahieren
  - manpages nach HTML wandeln
  - manpages ausliefern
- Laufzeitumgebung
- Fazit und Fragen

Motivation

- manpages im Browser lesen ist oft bequem
- existierende manpage-Archive generell unvollständig, alt, voll mit Werbung
- manpages.debian.org war zeitweise überlastet, generell wenig bekannt und wirkte mittlerweile recht altbacken

Kurze Demo

- für diejenigen, die manpages.debian.org noch nicht gesehen haben — Details folgen im Vortrag

Übersicht (sehr grob)

- manpages werden aus Debian extrahiert
- manpages werden nach HTML umgewandelt
- manpages werden an Endnutzer ausgeliefert

manpages extrahieren

- Debian besteht aus „source packages“, aus denen „binary packages“ gebaut werden

- während z.B. Debian Code Search nur source packages indexiert, nutzt manpages.d.o nur binary packages: viele Pakete generieren ihre manpages

- Pakete ohne `/usr/share/man` (laut `Contents`) werden übersprungen
  → nur 10G statt 50G laden beim ersten Durchlauf

manpages extrahieren (2)

- binary packages sind Architektur-abhängig, z.B. `amd64` vs. `i386`

- manpages befinden sich in `/usr/share/man`[1], was Architektur-unabhängig[2] ist

- aber: manche Pakete gibt es nur für wenige Architekturen, z.B. zsnes (nur `i386`)

  → wir müssen den Zusammenschluss aller Architekturen verarbeiten

Dateistruktur in `/usr/share/man`

- `/usr/share/man/(<lang>/|)man<section>/<name>.<section>.gz`

  → `/usr/share/man/man1/wget.1.gz`

  → `/usr/share/man/fr.ISO8859-1/man8/iwlist.8.gz`

  → `/usr/share/man/ca@valencia/man1/deja-dup.1.gz`

- Allerlei unsinnige Pfade in Debian:

  → Dateien in `man/py/man1` (von `.py`-Dateien)

  → falsches Suffix (z.B. `man`**`1`**`/foo.`**`3`**`.gz`)

  → …

Encoding

- Default für manpages: ISO-8859-1,

  aber für jedes subdirectory anders, z.B. `hu/` nutzt ISO-8859-2

  …und natürlich überschreibbar via subdirectory (z.B. `fr.ISO8859-1/`)

- Trotz fehlender Kennzeichnung nutzen in der Praxis 98,8% manpages UTF-8.

- debiman wandelt beim Einlesen alles in UTF-8

  → wenn später alles UTF-8 ist, haben wir es einfach

Der `.so`-Mechanismus

- Manpages können andere Dateien einbinden (include),

  z.B. header- oder footer-Fragmente, die vielen Manpages gemein sind

- `man(1)` nutzt `zsoelim(1)` um `.so`-Direktiven zu ersetzen

- Randnotiz: der Fehlerfall führt zu einer Ersetzung durch nichts, und es gibt mindestens ein Paket mit fehlerhaften `.so`-Direktiven

Manpages nach HTML wandeln

- erster Versuch: grohtml

  → erzeugt sehr vollständige Seiten, aber mit HTML-Tabellen und Bildern

- zweiter Versuch: doclifter, wandelt manpages nach docbook

  → inkompatibel mit >50% an manpages, langsam, Encoding-Probleme

- schließlich: mandoc, ein Rewrite von OpenBSD-Leuten

  → Schnell! Produziert semantisches HTML5. Ziemlich kompatibel (nicht perfekt)

mandoc: batch-Modus

- mandoc liest Dokumente von `stdin`, schreibt nach `stdout`/`stderr`

- Umwandeln von 470.000 manpages: 2 Stunden

  → größtenteils `fork`/`exec`-Overhead

  → was ist die eleganteste Art, mandoc einen batch-Modus zu verpassen?

mandoc: batch-Modus (2)

- `socketpair(2)`, einen Socket an `mandocd` vererben beim starten

- über den Socket 3 file descriptors schicken als Ersatz für `stdin`, `stdout`, `stderr`

  → siehe `cmsg(3)` für Versenden von file descriptors

  → siehe `dup2(2)` für Ersetzen von file descriptors

- Implementation in debiman und mandoc

Manpages nach HTML wandeln: cross-referencing

- nach allem suchen, was wie `<name>(<section>)` aussieht

  → nein, es gibt kein (verbreitetes) Markup dafür

  → Formatierungs-direktiven ignorieren

- erfordert, dass die Namen aller Manpages vor dem Umwandeln bekannt sind

- selber Mechanismus für URLs. Edge-case: URLs, die cross-references enthalten

Manpages nach HTML wandeln: table of contents

- nach `<h1>`- bis `<h6>`-Elementen suchen, IDs generieren

- HTML5-IDs: at least 1 character, no spaces:

```
id := strings.Replace(text, " ", "_", -1)
u := url.URL{Fragment: id}
fmt.Println(u.String())
```

Manpages ausliefern: URLs

- `/(<suite>/)(<binarypkg/>)<name>(.<section>(.<lang>))`

  jeder Teil (außer `<name>`) kann weggelassen werden

  → manpages.debian.org/i3

  → manpages.debian.org/stable/i3.1

  → manpages.debian.org/stretch/i3.1

  → manpages.debian.org/jessie/cron/crontab.5.en.html

- Perma-Links am besten ohne Sprache, damit die richtige gewählt wird

Manpages ausliefern: redirects

- ausführlicher Mechanismus, um URLs zu vervollständigen

- als separater Server implementiert (`debiman-auxserver`)

  → Hauptteil der Seite kann statisch ausgeliefert werden

  → graceful degradation

Manpages ausliefern: Sprach-Erkennung

- Accept-Language HTTP-Header

  z.B. `fr-CH, fr;q=0.9, en;q=0.8, de;q=0.7, *;q=0.5`

- vollständiger Language Match

  z.B.: Norwegisch-Sprecher können dänische Seiten verstehen

Manpages ausliefern: opensearch.xml

- Beschreibungsdatei für Suchmaschinen

  → Adresszeile/Suchfeld: manp<TAB> wget<ENTER>

  → https://manpages.debian.org/jump?q=wget

  → https://manpages.debian.org/jessie/wget/wget.1.en.html

Laufzeitumgebung

- `manziarly` ist eine VM auf einem HP BladeSystem bei Bytemark Hosting

  AMD Opteron™ 23xx-System (2008/2009)

  2 GB RAM, Storage ist spinning disk

  → Größenordnungen: Minuten (workstation), Stunden (manziarly) (Messwerte)

  → Geschwindigkeit ist wichtig: disaster recovery, developer velocity

- DSA (Debian System Administrators) nutzt ausschließlich Apache2

Laufzeitumgebung: static mirroring

- Debian (und Tor) nutzen ein static mirroring setup von Peter Palfrader (weasel)

  `rsync(1)` zum Verteilen auf mehrere Server

  DNS-Anpassungen vor geplanten Wartungsarbeiten (z.B. Kernel-Upgrades)

- debiman wurde angepasst, um gut damit zu funktionieren

  → `debiman-auxserver` redirects in Apache2-config re-implementiert

Laufzeitumgebung: static mirroring (rewritemap)

```
debiman-idx2rwmap \
  -index=/srv/manpages.debian.org/www/auxserver.idx \
  -output_dir=$TMPDIR

LC_ALL=C sort ${TMPDIR}/output.* > ${TMPDIR}/rwmap.txt

echo -n
H4sICEEvilgAA2VtcHR5My5kYm0A7dexCYBADIXhF+GK624DLVxAbJzBMVzBNRzO0tpJPDnlRLEW
4f8gJCRkgCdJpmRonPw+hFg+7c7b1dguqmPv+nmdyrwvjl69/AEAAAAAgO+YHnk9mMu3O/I/AAAA
AAD/sgEYIbKQACAAAA== | base64 -d | gunzip -c > ${TMPDIR}/rwmap.dbm

/usr/sbin/httxt2dbm -f DB -i ${TMPDIR}/rwmap.txt -o ${TMPDIR}/rwmap.dbm
```

Laufzeitumgebung: static mirroring (apache2)

```
# Replace e.g. pt-BR with pt_BR.
RequestHeader edit Accept-Language "-" "_" early
# Only SetEnvIf gets called _before_ RewriteRule
SetEnvIf Accept-Language "^(.*)$" ACCLANG=$1
SetEnvIf Accept-Language "^$" ACCLANG=en
RewriteEngine on
RewriteMap all dbm:/srv/man/rwmap-all.dbm
    # chomp off the first language tag
    RewriteCond "%{env:ACCLANG}" "^([^,;]+)"
    RewriteRule .* - [E=ACCTOK:%1]
    RewriteCond "${all:$1.%{env:ACCTOK}}" "^(.+)$"
    RewriteRule ^(.+)$ /%1 [redirect=307,last]
# while ACCLANG is non-empty, repeat
RewriteCond "%{env:ACCLANG}" "^(?:[^,]+),(.+)"
RewriteRule .* - [E=ACCLANG:%1,N]
# fallback: language is already included?
RewriteCond "${all:$1}" "^(.+)$"
RewriteRule ^(.+)$ /%1 [redirect=307,last]
```

Auszug! Vollständige Version:
80 Zeilen mod_rewrite-Config

Laufzeitumgebung: CDNs/cloud

- Statische Seiten überall einfach zu nutzen, debiman-auxserver einfach zu deployen

```
server {
 listen 80;
 root /srv/man;
 expires 1h;
 location / {
  rewrite ^/?$ /index.html;
  gzip_static always;
  gunzip on;
  error_page 404 = @auxserver;
 }

 location @auxserver {
  proxy_pass http://localhost:2431;
 }
}
```

```
[Unit]
Description=debiman auxiliary service
endpoints

[Service]
Restart=always
StartLimitInterval=0
User=nobody
Group=nogroup
ExecStart=/usr/bin/debiman-auxserver
PrivateTmp=true
ProtectSystem=strict

[Install]
WantedBy=multi-user.target
```

Edge case: slave alternative manpages

- Debian-Mechanismus für Wahl einer Implementation (z.B. x-www-browser, vi)

  ⟶ nicht nur symlinks für Binaries, auch für manpages

- `update-alternatives(8)`-Aufrufe im postinst-Script

  ⟶ wird zur Laufzeit eingerichtet, keine formelle API

  ⟶ wir müssten Pakete installieren (ugh)

- `piuparts(1)`-Patch zeichnet `update-alternatives(8)`-Aufrufe auf

Fazit: manpages.debian.org

- Mobil-Layout für Smartphones, Tablets, etc.

seite/test	crontab.5	gbp.1	javafxpackager.1	zsnes.1	tophat.1	w3m.1.ja	w3m.1.de
m[…].debian	alle ☺	✔	✔	✔	✔	✔	✔
m[…].ubuntu	systemd-cron	✔	✘	✔	✔	❓	✔
man.cx	cron	stable	✘	✔	✘	✔	✘
linux.die.net	cron	✘	✘	✘	✘	✘	✘
mankier.com	cron	✘	✘	✘	✘	✘	✘
man.he.net	BSD	✘	✘	✘	✘	✘	✘
man7.org	cronie	✘	✘	✘	✘	✘	✘

Fazit: Go

- Funktionalität größtenteils implementierbar mit der standard library,

  `golang.org/x/{text,net/html}` und `pault.ag/go/debian`

- Nebenläufigkeit einfach umzusetzen

  → maximale Ressourcen-Ausnutzung einfach erreichbar

- Auf `manziarly` (2G RAM) musste man auf Speicher aufpassen

  → Profiler pprof hilft

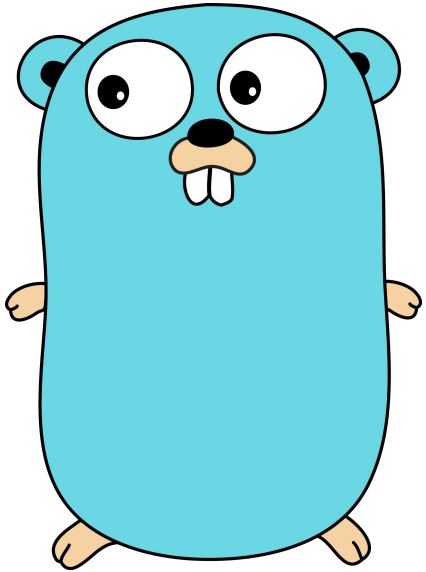

Fragen?

- Mehr Infos auf https://github.com/Debian/debiman

- Interesse an einer debiman-Instanz für deine Lieblings-Distro? Sprich mich an!

- Danke für die Aufmerksamkeit! Fragen?

- Feedback zum Vortrag

(Bonus) Manpages ausliefern: webfont loading

- Browser nutzen FOIT (Flash Of Invisible Text) statt FOUT (Flash Of Unstyled Text)

  → auf langsamen Verbindungen (z.B. 2G) ist 10s lang kein Inhalt zu sehen

- Browser-support für verschiedene Features sehr unterschiedlich:

  JavaScript, Font Loading API, Preloading, WOFF/WOFF2, Font Display API

- Details zur Lösung auf https://michael.stapelberg.de/Artikel/font-loading