OCR mit cuneiform

Jürgen Weigert
openSUSE user
2010-06-01

Novell

OCR – Optical Character Recognition

Was gibt es für Linux?

- GOCR / kOCR
- Tesseract
- Cuneiform
- ...

Was gibt es da zu Hacken?

- Ausprobieren, dokumentieren was geht
- Trainieren, Erkennungsraten erhöhen
- GUI? – oft Fehlanzeige → Klaas fragen
- Scripte für Formatkonvertierungen
  - Dateiformat hocr ← offener Standard in XML
- …

Scannen für cuneiform

- Graustufen TIFF, oder schwarz/weiss
  - Nicht “mTIFF” mit unseren OfficeScannern!
- 200 oder 300 dpi
  - Mehr ist besser ...
- Seitenorientierung muss stimmen
  - Wenn nötig mit gimp drehen
- Fotos in Graustufen umwandeln,
  - Auf gleichmäßige Ausleuchtung achten

Software Installation

cuneiform-0.8.0

Aus home:jnweiger:branches:home:Lazy_Kent / openSUSE_11.2, openSUSE_11.3

- In Version 0.9.0 ist die Ausgabe von hocr defekt: bugs.launchpad.net/cuneiform-linux/+bugs/548801
- In Version 0.8.0 führen PNG Bilder zu SEGFAULT

exactimage-0.8.0 aus home:jnweiger

Weitere “soft dependencies”

→ scanimage, gimp, xv, gwenview, okular, …

Vorführung

Projektidee “wo-ist-oben?”

- Ein Script um scanimage
  - Rotieren um 0°, 90°, 180° und 270°
  - In allen vier Richtungen OCR laufen lassen
  - Erkennungsrate jeweils messen
  - Das mit der höchsten Rate ist richtig herum!

Projektidee “Sandwich-PDF”

- Office-Scanner schickt PDF per e-mail
- PDF auspacken → nach TIFF konvertieren
- Projektidee “wo ist oben” anwenden

```
$ cuneiform -l ger -f hocr -o X.hocr X.tif
$ hocr2pdf -i X.tif -o X.pdf -s < X.hocr
```

Projektidee “Sandwich-PDF”

- Office-Scanner schickt PDF per e-mail
- PDF auspacken → nach TIFF konvertieren
- Projektidee “wo ist oben” anwenden

```
$ cuneiform -l ger -f hocr -o X.hocr X.tif
$ hocr2pdf -i X.tif -o X.pdf -s < X.hocr
```

- Automatisieren mit einem e-mail Dienst

  Office-Scanner schickt an <username>@ocr

Projektidee “Geheimschrift Fraktur”

- Einen Font für gotische Schriften trainieren
- Besser lesbar nach OCR?

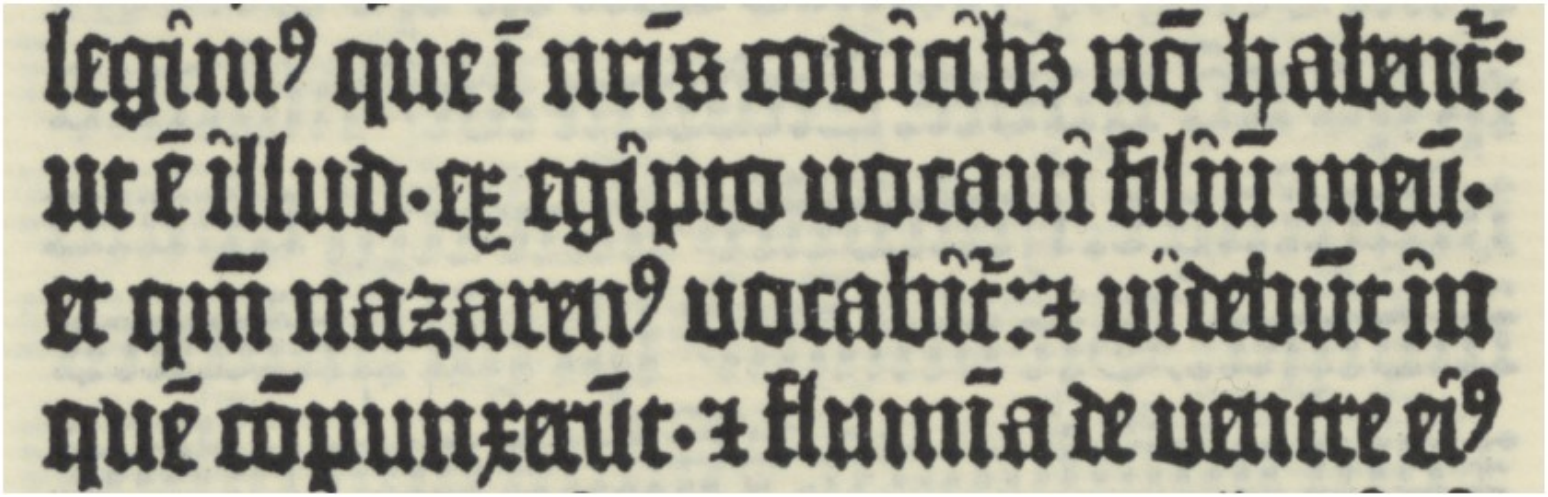

Novell

Die Typen der 42zeiligen Bibel

a. Gutenbergtypen

Viel Spass!

Novell®

General Disclaimer

This document is not to be construed as a promise by any participating company to develop, deliver, or market a product. Novell, Inc., makes no representations or warranties with respect to the contents of this document, and specifically disclaims any express or implied warranties of merchantability or fitness for any particular purpose. Further, Novell, Inc., reserves the right to revise this document and to make changes to its content, at any time, without obligation to notify any person or entity of such revisions or changes. All Novell marks referenced in this presentation are trademarks or registered trademarks of Novell, Inc. in the United States and other countries. All third-party trademarks are the property of their respective owners.

Novell