

Macoun

Optical Character Recognition auf dem iPhone

Hendrik von Prince

Ablauf

- Eckdaten von Tesseract
- Funktionsweise von Tesseract
- Einbindung in einer iOS-App
- Ergebnisse verbessern
- Ausblick

Eckdaten von Tesseract

1. 1984 bei HP entstanden
2. Seit 2005 von Google weiterentwickelt
3. Stabile Version 3.05.02 vom 19. Juni 2018
4. Apache Lizenz
5. De-Facto-Standard zum Erkennen von Text

Funktionsweise von Tesseract

1. Initialisiere Tesseract mit einem trainierten Modell
2. Bild-Vorverarbeitung
3. Seiten-Layout-Analyse
4. Schriftlinien- und Wort-Detektion
5. Worterkennung (erste Phase)
6. Worterkennung (zweite Phase)

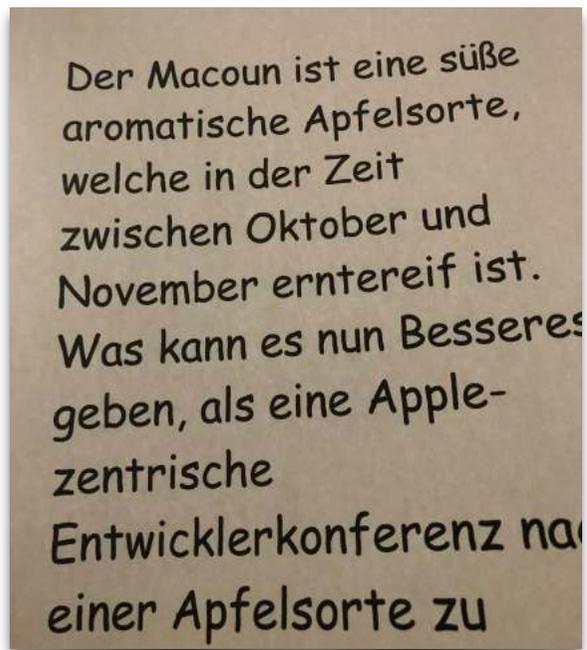
Funktionsweise von Tesseract

INITIALISIERE TESSERACT MIT EINEM TRAINIERTEN MODELL

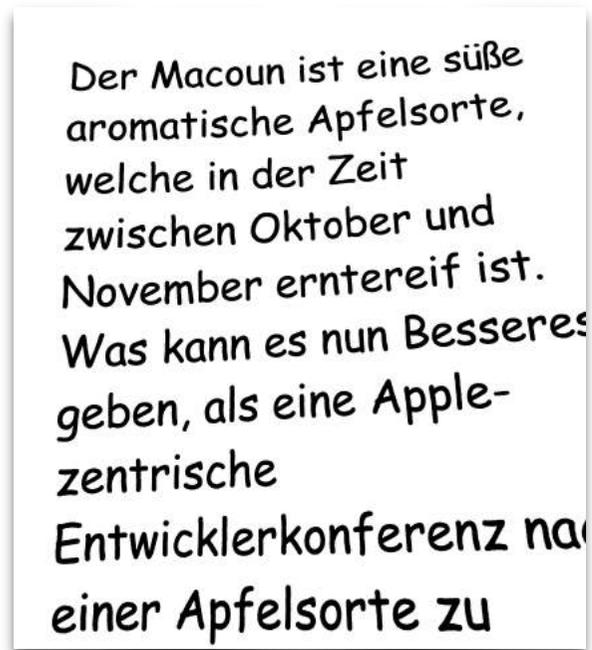
- Ein Modell ist nur für eine Sprache trainiert
- Kann aber gleichzeitig für mehrere Fonts trainiert worden sein

I. Bild Vorverarbeitung

UMWANDLUNG IN SCHWARZ-WEIß

A rectangular area with a brown, textured background. The text is written in a black, sans-serif font, rotated slightly counter-clockwise. The text is a German description of the Macoun apple variety.

Der Macoun ist eine süße
aromatische Apfelsorte,
welche in der Zeit
zwischen Oktober und
November erntereif ist.
Was kann es nun Besseres
geben, als eine Apple-
zentrische
Entwicklerkonferenz nach
einer Apfelsorte zu

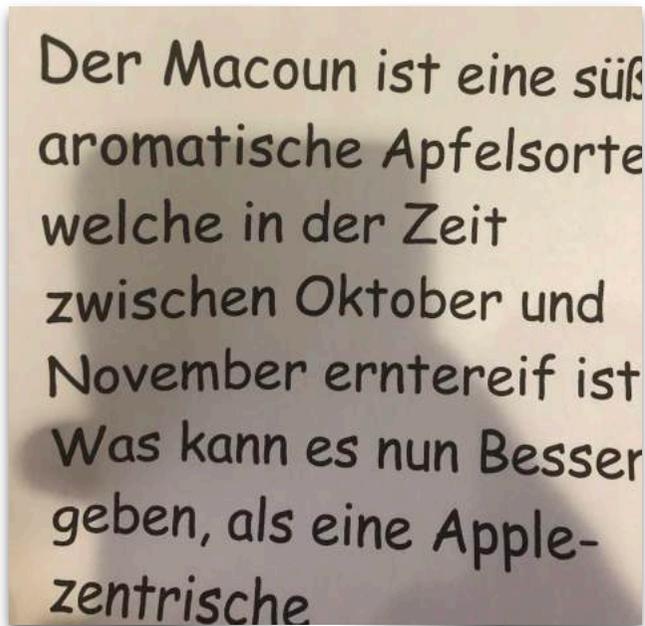
A rectangular area with a white background. The text is written in a black, sans-serif font, rotated slightly counter-clockwise. This is the same text as in the brown background block, but with a white background.

Der Macoun ist eine süße
aromatische Apfelsorte,
welche in der Zeit
zwischen Oktober und
November erntereif ist.
Was kann es nun Besseres
geben, als eine Apple-
zentrische
Entwicklerkonferenz nach
einer Apfelsorte zu

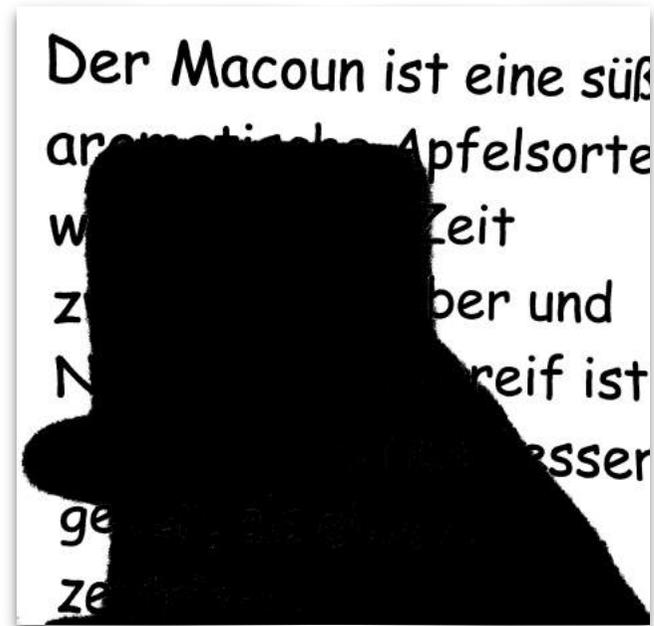
Zitiert von: <https://macoun.de/about>

I. Bild Vorverarbeitung

STOLPERFALLE: UMWANDLUNG IN SCHWARZ-WEIß



Der Macoun ist eine süß
aromatische Apfelsorte
welche in der Zeit
zwischen Oktober und
November erntereif ist
Was kann es nun Besser
geben, als eine Apple-
zentrische

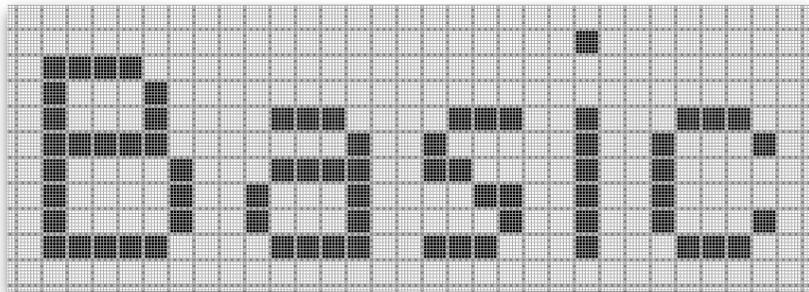


Der Macoun ist eine süß
aromatische Apfelsorte
welche in der Zeit
zwischen Oktober und
November erntereif ist
Was kann es nun Besser
geben, als eine Apple-
zentrische

Zitiert von: <https://macoun.de/about>

2. Seiten-Layout-Analyse

- Erkenne zusammenhängende Pixel-Regionen (Connected Component Analysis)

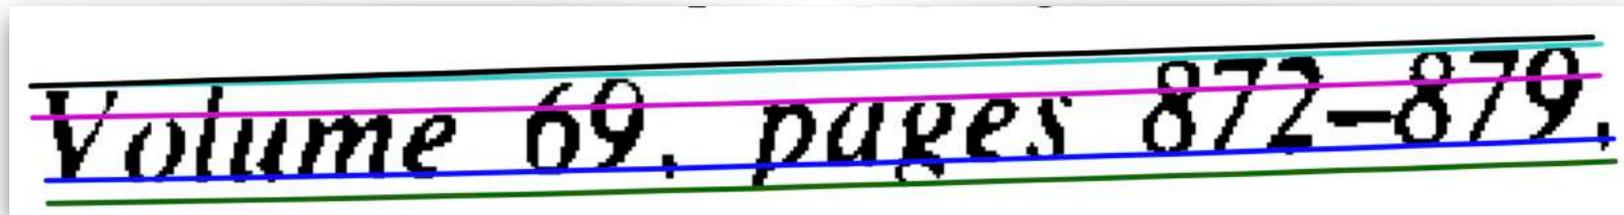


Bildauthor: Vijay.r.nadar (<https://commons.wikimedia.org/wiki/File:OCRBasic.png>)

- Unterscheide Text von Nicht-Text (Hartkodierte, heuristikbasierte Logik)

Schriftlinien- und Wort-Detektion

- Erkenne Zeilen
- Finde die Schriftlinie pro Zeile



Bildquelle: An Overview of the Tesseract OCR Engine (2007), Seite 2

Schriftlinien- und Wort- Detektion

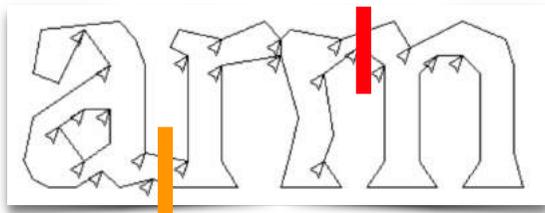
- Für jede Zeile:
 - Unterscheidung von Monospace / Nicht-Monospace-Fonts
 - Gruppiere zusammenhängende Pixel-Regionen zu Wortregionen

Worterkennung (erste Phase)

- Für Monospace-Fonts:
 - Unterteile jede Wortregion in gleichgroße Teile
- Für Nicht-Monospace-Fonts:
 - Unterteile jede Wortregion anhand der Zwischenräume der einzelnen enthaltenen Pixelregionen
- Klassifizierung der enthaltenen Pixelregionen als Zeichen
- Eintragen aller erkannten Worte in ein internes Wörterbuch

Worterkennung (zweite Phase)

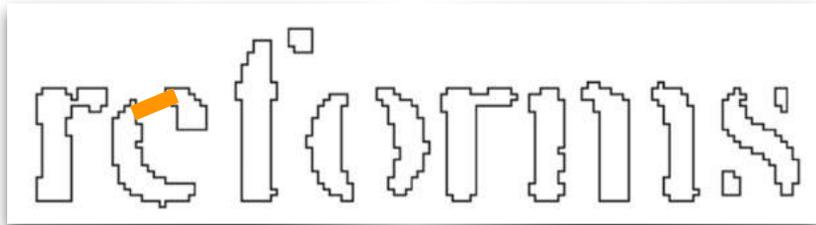
- Durchlaufe alle erkannten Worte und bewerte sie anhand von einem vorgegebenen Wörterbuch und dem internen Wörterbuch
- Solange die Bewertung vom Wort zu ungenau ist, werden die Zeichen mit der geringsten Genauigkeit weiter unterteilt



Bildquelle: An Overview of the Tesseract OCR Engine (2007), Seite 3

Worterkennung (zweite Phase)

- Anschließend werden Pixelregionen zusammengeführt



Bildquelle: An Overview of the Tesseract OCR Engine (2007), Seite 3

- Bewertung vom resultierenden Wort anhand von den Wörterbüchern
- Wähle das Wort mit der beste Bewertung

Zusammenfassung

RESISTENT GEGEN

- Schlechte Bildqualität
- Rotierten Texte
- Fontvariationen
- Sich wiederholenden fachspezifischen Wörtern
- Schwarz/weiß weiß/schwarz

Zusammenfassung

SCHWIERIGKEITEN ERGEBEN SICH MIT

- Dreckigem / gemustertem Hintergrund
- Starke halbseitige Schatten
- Unterschiedliche Fonts / Fontgrößen innerhalb einer Zeile
- Wechselnde Fontfarben
- Vom Training stark abweichende Fonts

Einbindung in einer iOS-App

COCOAPOD TESSERACTOCRIOS

- Basiert auf Tesseract 3.03-rc1
- Wird kaum weiterentwickelt, funktioniert aber noch
- Sehr gute API
- Keine Bitcode-Unterstützung

Einbindung in einer iOS-App

COCOAPOD TESSERACT-OCR-IOS

```
inhibit_all_warnings!  
  
target 'TesseractDemo' do  
  use_frameworks!  
  
  pod 'TesseractOCRiOS'  
end
```

Einbindung in einer iOS-App

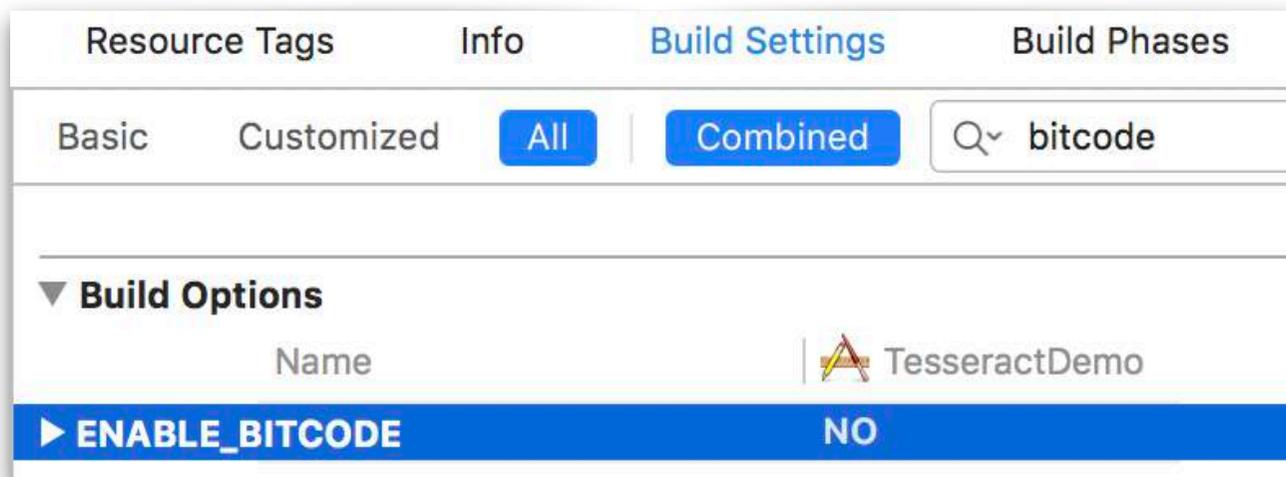
COCOAPOD TESSERACT-OCR-IOS

```
post_install do |installer|
  installer.pods_project.targets.each do |target|
    target.build_configurations.each do |config|
      config.build_settings['ENABLE_BITCODE'] = 'NO'
    end
  end
end
```

Einbindung in einer iOS-App

COCOAPOD TESSERACT-OCR-IOS

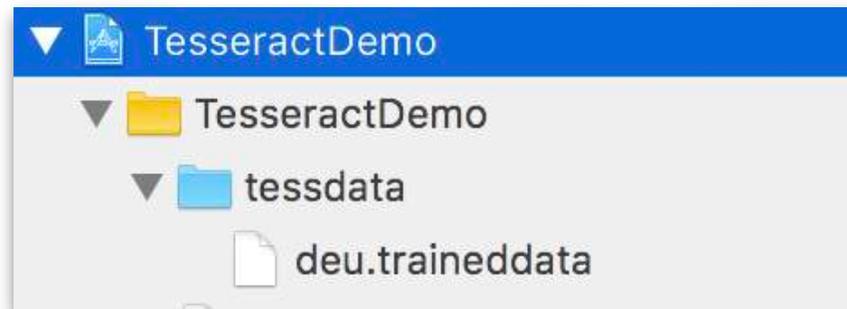
- Bitcode im App-Target deaktivieren



Einbindung in einer iOS-App

SPRACHDATEIEN EINBINDEN

- *tessdata*-Verzeichnis anlegen und als *Folder Reference* in das Projekt ziehen
- Trainierte Sprachdateien von <https://github.com/tesseract-ocr/tessdata/tree/3.04.00> herunterladen und in das *tessdata*-Verzeichnis ablegen



Einbindung in einer iOS-App

TESSERACT AUF EIN BILD ANWENDEN

```
import TesseractOCR

let tesseract = G8Tesseract(language: "deu")!
tesseract.image = UIImage(named: "testbild")
tesseract.recognize()
print(tesseract.recognizedText)
```

Einbindung in einer iOS-App

MEHRERE SPRACHEN LADEN

```
let tesseract = G8Tesseract(language: "deu+eng")
```

Ergebnisse verbessern

- Tesseract's Bildvorverarbeitung austauschen
- Tesseract-Parameter tunen
- Vision
- Eigene Fonts antrainieren

Tesseract's Bildverarbeitung austauschen

- Implementieren von `G8TesseractDelegate`
- Filter aus dem Pod `GPUImage` verwenden
- Eigene Bildverarbeitungsalgorithmen in `CIFilter` implementieren und auf den Use-Case anpassen

Tesseract's Bildverarbeitung austauschen

G8TESSERACTDELEGATE + GPUIMAGE

```
func preprocessedImage(for tesseract: G8Tesseract!,
                       sourceImage: UIImage!) -> UIImage!
{
    let filter = GPUImageLuminanceThresholdFilter()
    filter = 0.3
    return filter.image(byFilteringImage: sourceImage)
}
```

Tesseract's Bildverarbeitung austauschen

G8TesseractDelegate + GPUImage

Der Macoun ist eine süß
aromatische Apfelsorte
welche in der Zeit
zwischen Oktober und
November erntereif ist
Was kann es nun Besser
geben, als eine Apple-
zentrische

Der' Macoun ist eine süß
aromatische Apfdsorfe welche
in der Zeit zwischen Okfober
und November' ernfereif ist
Was kann es nun Besser
geben, als eine Apple-
zentrische

Tesseract-Parameter tunen

```
> tesseract --print-parameters
```

Tesseract-Parameter tunen

```
> tesseract --print-parameters
Tesseract parameters:
editor_image_xpos 590 Editor image X Pos
editor_image_ypos 10 Editor image Y Pos
editor_image_menuheight50 Add to image height for menu bar
editor_image_word_bb_color 7 Word bounding box colour
editor_image_blob_bb_color 4 Blob bounding box colour
editor_image_text_color2 Correct text colour
editor_dbwin_xpos 50 Editor debug window X Pos
editor_dbwin_ypos 500 Editor debug window Y Pos
editor_dbwin_height 24 Editor debug window height
editor_dbwin_width80 Editor debug window width
```

Tesseract-Parameter tunen

```
> tesseract --print-parameters
editor_word_xpos 60 Word window X Pos
editor_word_ypos 510 Word window Y Pos
editor_word_height 240 Word window height
editor_word_width 655 Word window width
textord_debug_tabfind 0 Debug tab finding
textord_debug_bugs 0 Turn on output related to bugs in tab
finding
textord_testregion_left -1 Left edge of debug reporting rectangle
textord_testregion_top -1 Top edge of debug reporting rectangle
textord_testregion_right 2147483647 Right edge of debug
rectangle
```

Tesseract-Parameter tunen

```
> tesseract --print-parameters
textord_testregion_bottom 2147483647 Bottom edge of debug
rectangle
textord_tabfind_show_partitions 0 Show partition bounds, waiting
if >1
devanagari_split_debuglevel 0 Debug level for split shiro-rekha
process.
edges_max_children_per_outline 10 Max number of children inside
a character outline
edges_max_children_layers 5 Max layers of nested children inside
a character outline
edges_children_per_grandchild 10 Importance ratio for chucking
```

Tesseract-Parameter tunen

```
> tesseract --print-parameters
textord_test_y -2147483647 coord of test pt
textord_min_blobs_in_row 4 Min blobs before gradient counted
textord_spline_minblobs 8 Min blobs in each spline segment
textord_spline_medianwin 6 Size of window for spline segmentation
textord_max_blob_overlaps 4 Max number of blobs a big blob can
overlap
textord_min_xheight 10 Min credible pixel xheight
textord_lms_line_trials 12 Number of line fits to do
oldbl_holed_losscount 10 Max lost before fallback line used
pitsync_linear_version 6 Use new fast algorithm
pitsync_fake_depth 1 Max advance fake generation
```

Tesseract-Parameter tunen

+ 650 weitere

Tesseract-Parameter tunen

```
let minXHeight = "\(Int(image.size.height * 0.05))"  
tesseract.setVariableValue(minXHeight, forKey: "textord_min_xheight")  
tesseract.setVariableValue("", forKey: "tessedit_char_blacklist")
```

```
Der Macoun ist eine süß aromatische  
Apfelsorfe welche in der Zeit zwischen  
Okfober und November ernfereif ist Was  
kann es nun Besser geben, als eine  
Apple- zentrische
```

Tesseract-Parameter tunen

- `tessedit_char_blacklist / tessedit_char_whitelist`
- `textord_noise_hfract, textord_heavy_nr`
- `load_system_dawg, load_number_dawg,
load_fixed_length_dawgs`
- `load_bigram_dawg`
- Kurze Beschreibung zu den einzelnen Parametern: <http://www.sk-spell.sk.cx/tesseract-ocr-parameters-in-302-version>

Vision

- Framework von Apple ab iOS 11.0
- Detektiert Rechtecke, Gesichter, Barcodes,... und Text
- Texterkennung funktioniert unabhängig von der Sprache und Font
- Sehr performant

=> Berechne mit Vision in welchem Bildbereich sich Text befindet und übergebe nur diesen an Tesseract

Vision

Der Macoun ist eine süße aromatische Apfelsorte, welche in der Zeit zwischen Oktober und November erntereif ist.

Was kann es nun Besseres geben, als eine Apple-zentrische Entwicklerkonferenz nach einer Apfelsorte zu benennen, denn seit 2008 ist es auch die größte deutschsprachige Entwicklerkonferenz für macOS und iOS Entwickler.

Vor kurzem wurde uns mitgeteilt, dass die Macoun sogar die mittlerweile größte Entwicklerkonferenz in Europa mit Fokus auf Apple-Systemen ist.

Der Apfel als Symbol der Firma, für deren Rechner und Systeme wir entwickeln und deren Inbegriff seit 1984 der Macintosh Computer ist. Diese Analogie fanden wir sehr passend und aus diesem Grund heißt die Konferenz und diese Seite hier macoun.de - und aus denselben Gründen veranstalten wir nun zum elften Mal die Macoun in Deutschland.

Der' Macoun ist eine süße aromatische Apfelsorte, welche in der Zeit zwischen Oktober und November erntereif ist.

[...]

Diese Analogie fanden wir sehr passend und aus diesem Grund heißt die Konferenz und diese Seite hier macoun.de - und aus denselben Gründen veranstalten wir nun zum elften Mal die Macoun in Deutschland.

Vision

```
import Vision

let handler = VNImageRequestHandler(ciImage: image,
                                    orientation: .up,
                                    options: [:])

let textDetect = VNDetectTextRectanglesRequest()
let requests = [textDetect]
try? handler.perform(requests)
```

Vision

```
let results = textDetect.results as! [VNTextObservation]
let boundingBoxes = results.map({ $0.boundingBox })
var regionWithText = combine(boundingBoxes)
regionWithText = regionWithText.insetBy(dx: -50, dy: -50)

Let croppedCGImage = image.cgImage!.cropping(to: regionWithText)!

tesseract.image = UIImage(cgImage: croppedCGImage)
```

Vision

DC!' Macoun ist eine süße
aromatische Apfelsarte, welche
in der Zeit
zmschen Oktober und November
erntereif ist.

[...]

und aus

Gründen veranstalten wir nun
zum elften Mal die Macoun

\' " \' \' r " - " . ' \\'

61 Fehler

Der' Macoun ist eine süße
aromatische
Apfelsorte, welche in der
Zeit
zwischen Oktober und November
erntereif ist.

[...]

und aus

denselben Gründen

veranstalten wir nun zum
elften Mal die Macoun
in Deutschland.

1 Fehler

Eigene Fonts antrainieren

- Variante eins: <http://trainyourtesseract.com/>

The screenshot shows a web form with three numbered steps:

- 1** Email: A text input field containing the word "Email".
- 2** Character selection: A grid of checkboxes for font features:
 - Upercase Letters
 - Lowercase Letters
 - Numbers
 - Special Chars <>-.+;:\
 - Umlauts
 - Newsletter

Please make sure that you only check the boxes that are included in your font.
- 3** File upload: A file input field with a "Choose file" button and the text "No file chosen".

Bildquelle: <http://trainyourtesseract.com/>, Abgerufen am 12.09.2018

Eigene Fonts antrainieren

[HTTP://TRAINYOURTESSERACT.COM/](http://trainyourtesseract.com/)

- Liefert kleine Dateien mit Ergebnissen die für manche Anwendungsfälle ausreichen können

Eigene Fonts antrainieren

- Variante 2: Per Hand trainieren

Eigene Fonts antrainieren

PER HAND TRAINIEREN

- Tesseract 3.05 über homebrew installieren
- Trainings-Scripte installieren
- Trainings-Script für mac OS patchen
- Sprachdaten herunterladen
- Training starten

Eigene Fonts antrainieren

PER HAND TRAINIEREN

- Tesseract 3.05 über homebrew installieren

```
brew install tesseract --with-all-languages --with-training-tools
```

Eigene Fonts antrainieren

PER HAND TRAINIEREN

- Trainings-Scripte installieren

```
curl https://raw.githubusercontent.com/tesseract-ocr/tesseract/3.05/training/tesstrain.sh -o /usr/local/Cellar/tesseract/3.05.02/bin/tesstrain.sh
curl https://raw.githubusercontent.com/tesseract-ocr/tesseract/3.05/training/language-specific.sh -o /usr/local/Cellar/tesseract/3.05.02/bin/language-specific.sh
curl https://raw.githubusercontent.com/tesseract-ocr/tesseract/3.05/training/tesstrain_utils.sh -o /usr/local/Cellar/tesseract/3.05.02/bin/tesstrain_utils.sh
chmod +x /usr/local/Cellar/tesseract/3.05.02/bin/tesstrain.sh
```

Eigene Fonts antrainieren

PER HAND TRAINIEREN

- Trainings-Script für mac OS patchen

```
printf 'diff --git a/tesstrain_utils.sh b/tesstrain_utils.sh
      index 906a20ac..0701b80a 100755
      --- a/tesstrain_utils.sh
      +++ b/tesstrain_utils.sh
      @@ -28,2 +28,3 @@ EXTRACT_FONT_PROPERTIES=1
      WORKSPACE_DIR=`mktemp -d`
      +export PANGOCAIRO_BACKEND=fc
```

Eigene Fonts antrainieren

PER HAND TRAINIEREN

- Sprachdaten herunterladen

```
git clone https://github.com/tesseract-ocr/langdata
```

Eigene Fonts antrainieren

PER HAND TRAINIEREN

- Training starten

```
/usr/local/Cellar/tesseract/3.05.02/bin/tesstrain.sh --lang deu --langdata_dir ./langdata/ --tessdata_dir /usr/local/Cellar/tesseract/3.05.02/share/tessdata --fontlist "Comic Sans MS" --fonts_dir ~/custom-fonts
```

- “deu”: Der Font wird mit den Parametern für die deutsche Sprache trainiert
- “Comic Sans MS”: Der zu trainierende Font
- --fonts_dir: Nur nötig falls der Font nicht im System-Ordner liegt

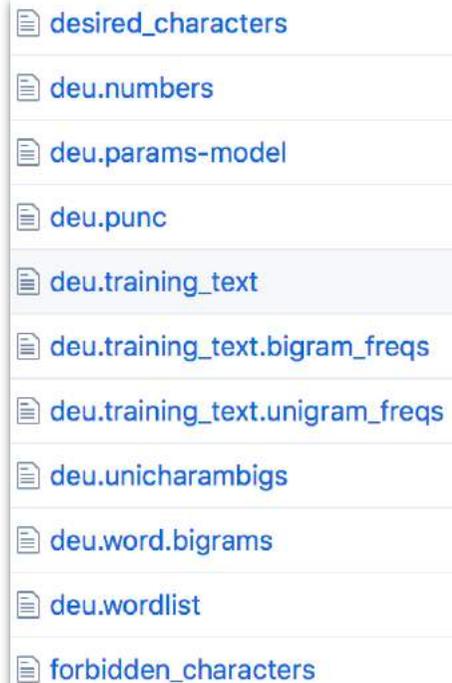
Eigene Fonts antrainieren

PER HAND TRAINIEREN

- Am Ende liegt in `/tmp/tesstrain/tessdata` die Datei `deu.traineddata`
- Ca. 12MB groß
- Training basiert auf mehreren Dateien die in `langdata/deu` enthalten sind
- Optimierbar für andere Fonts, Trainingstext, Characterähnlichkeiten, ...

Eigene Fonts antrainieren

PER HAND TRAINIEREN



- desired_characters
- deu.numbers
- deu.params-model
- deu.punc
- deu.training_text
- deu.training_text.bigram_freqs
- deu.training_text.unigram_freqs
- deu.unicharambig
- deu.word.bigrams
- deu.wordlist
- forbidden_characters

Zusammenfassung

- Tesseract initial einzusetzen ist sehr einfach
- Vermutlich sind die Ergebnisse anfangs relativ schlecht
- Mit den gezeigten Vorgehensweisen können sie signifikant verbessert werden
- 100% Genauigkeit: Stellt euch auf mehrere Wochen rumprobieren und Schmerzen ein.

Ausblick

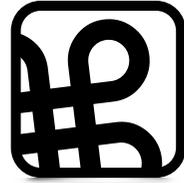
- Tesseract 4.0 mit Neuronalem Netz
 - Erste Alpha im November 2016
 - Aktuelle Beta vom 2. August
 - Pull-Request für TesseractOCRiOS
 - Sehr viel bessere Ergebnisse, dafür sehr viel langsamer

Ausblick

- Moderne “Alternative” SwiftOCR?
 - Laut eigenen Angaben nur für kurze (einzeilige) Texte geeignet, dann aber sehr viel schneller und genauer als Tesseract
- API von Apple?
 - Das Know-How besitzen sie
 - Allerdings weißt bisher nichts darauf hin

Fragen?

Vielen Dank



Macoun