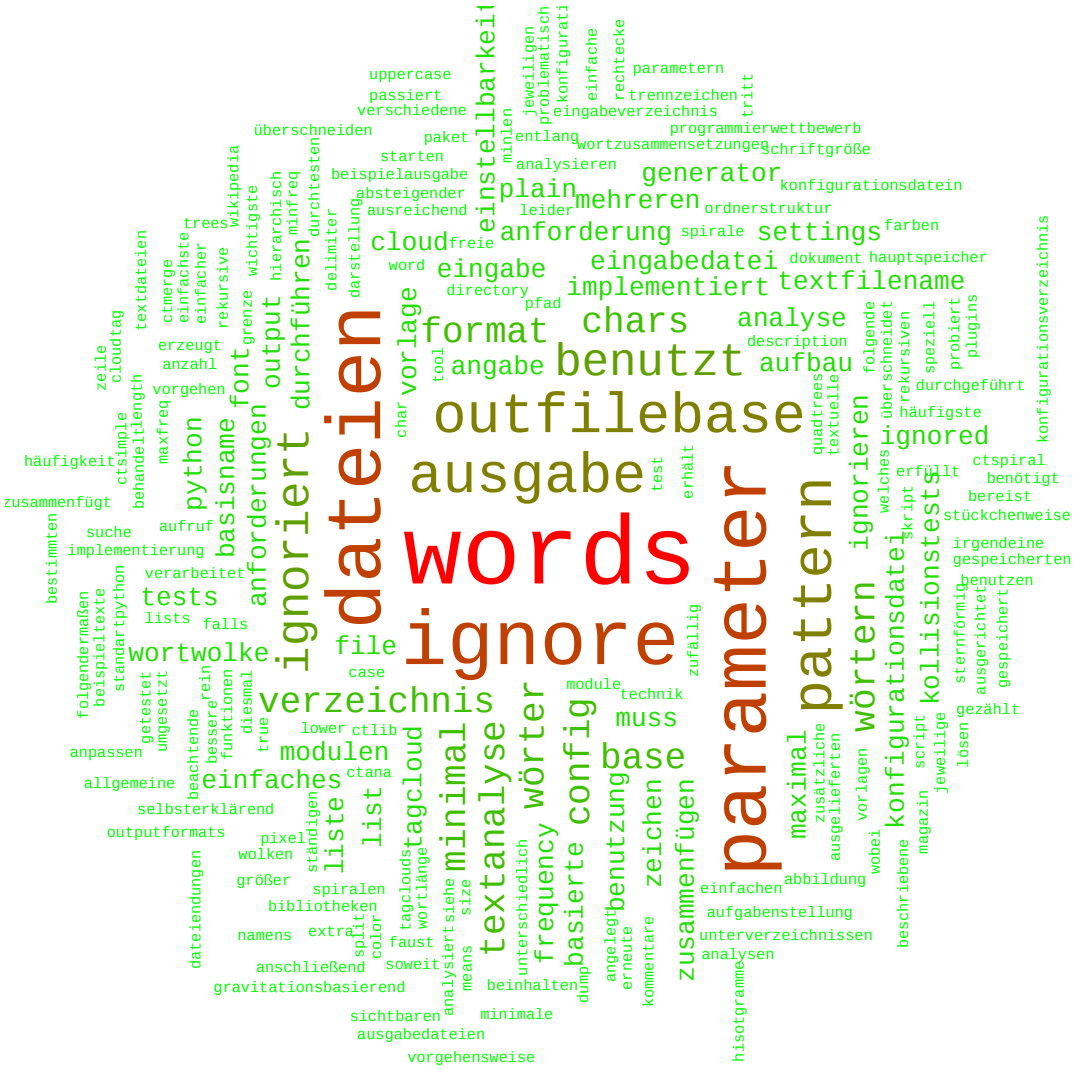

CloudTag

–Ein Tag Cloud Generator–

Programmierwettbewerb
Freies Magazin 04-2012

von: Steve Göring

Datum: 24. März 2012

Inhaltsverzeichnis

1 Aufgabenstellung

Beim Programmierwettbewerb für das Freie Magazin ging es diesmal um einen Tagcloud-Generator. Dabei sollten einige Anforderungen erfüllt werden:

- rein textuelle Analyse
- Eingabe von Trennzeichen
- rekursive Suche und Analyse von Dateien mit bestimmten Dateiendungen
- Angabe von mindestens einer Liste mit Wörtern, die ignoriert werden sollen
- Angabe von mindestens einer Liste mit Wörtern oder Wortzusammensetzungen, die speziell gezählt werden sollen (A)
- Einstellbarkeit für die Anzahl der sichtbaren Wörter in der Wortwolke
- Einstellbarkeit für die minimal zu beachtende Wortlänge
- Darstellung als Wortwolke

Die Anforderung(A) wurde bisher noch nicht umgesetzt, alle anderen sind implementiert.

2 Lösung/Aufbau

Der hier beschriebene Tagcloud-Generator namens 'Cloudtag' wurde in Python3 implementiert und benutzt nur die Standartpython Bibliotheken.

Er besteht aus mehreren Python3 Modulen:

ctlib.py einige Funktionen die von allen Modulen benutzt werden

ct.py einfaches all-one Skript

ctana.py Textanalyse

ctmerge.py Zusammenfügen von mehreren Textdateien in rekursiven Unterverzeichnissen

ctsimple.py einfache html basierte Ausgabe

ctspiral.py svg basierte Wolken-Ausgabe, benutzt Spiralen

Im ausgelieferten Paket findet man folgende Ordnerstruktur vor:

- cfg : Konfigurationsverzeichnis
  - ignore
    - chars.txt : Zeichen die ignoriert werden sollen
    - words.txt : Wörter die ignoriert werden
  - pattern
    - html.pat : html Vorlage

        - svg.pat : svg Vorlage
    - config.cfg : allgemeine Konfigurationsdatei
- in : Beispieltexte
- out : Beispielausgabe
- doc : diese Dokument

3 Konfiguration

Alle Module benutzen die gleichen Konfigurationsdatein aus dem Verzeichnis 'cfg'. Die 'ignore' Dateien haben dabei einen einfachen Aufbau, denn in jeder Zeile steht genau ein Wort bzw. ein Zeichen welches ignoriert werden soll.

Die wichtigste Konfigurationsdatei 'config.cfg'. Man kann Farben, Schriftgröße, die Dateien zum Ignorieren, verschiedene Vorlagen zur Ausgabe und andere Parameter anpassen. Sie sieht beispielsweise folgendermaßen aus:

```
[ignore] #ignore settings
# base directory for ignore lists
base = cfg/ignore/
# ignore lower / uppercase
case = True
# textfilename for ignored word list
words = words.txt
# textfilename for ignored char list
chars = chars.txt
[words] # tag cloud settings
# maximal words=-1 means use all words
max = -1
# maximal frequency of words
maxfreq = -1
# minimal frequency of words
minfreq = 10
# minimal length of words
minlen = 3
[font] # font size in pixel
max = 90
min = 14
[color]
min = 00FF00
max = FF0000
[pattern]
base = cfg/pattern/
# delimiter
split = #
# html pattern file
html= html.pat
# svg pattern
svg= svg.pat
[output]# outputformats
format = html,svg
```

Die Parameter sind soweit selbsterklärend

4 Benutzung

4.1 einfach

Die einfachste Möglichkeit bietet die Benutzung von 'ct.py'.
Ein './ct.py -h' zeigt Informationen zu den Parametern.

minimale Parameter

'ct.py' benötigt mindestens 2 Parameter, einmal 'in' und dann noch 'outfilebase':

'in' wobei 'in' die Eingabedatei oder das Eingabeverzeichnis ist und

'outfilebase' der Basisname (bzw. Pfad und Basisname) für die Ausgabedateien ist.

Möchte man z.b. nur eine Html Ausgabe, so muss man in der 'config.cfg' unter 'output' den Parameter 'format' auf 'format=html' setzen. Nach Aufruf von 'ct.py in outfilebase' werden dann die Dateien 'outfilebase'.plain und 'outfilebase'.html angelegt. Die '*.plain' Dateien beinhalten dabei das Ergebnis der Textanalyse in einfacher Form.

4.2 anderes Vorgehen

Man muss nicht jedes mal eine erneute Textanalyse durchführen, oder jedes mal die Eingabe Dateien zusammenfügen, sondern man kann jeden einzelnen Schritt der bei 'ct.py' durchgeführt wird auch mit dem jeweiligen extra 'ctX' Tool durchführen. Einfach das jeweilige Programm ohne Parameter starten und man erhält Informationen über die Parameter.

5 Technik/Tests

Mit dem Script 'test.sh' werden Dateien die im Verzeichnis 'in' unterschiedlich als TagClouds verarbeitet und im Verzeichnis 'out' gespeichert. Zum Beispiel sollte dabei eine Tag-Cloud zu 'Faust' erzeugt werden:

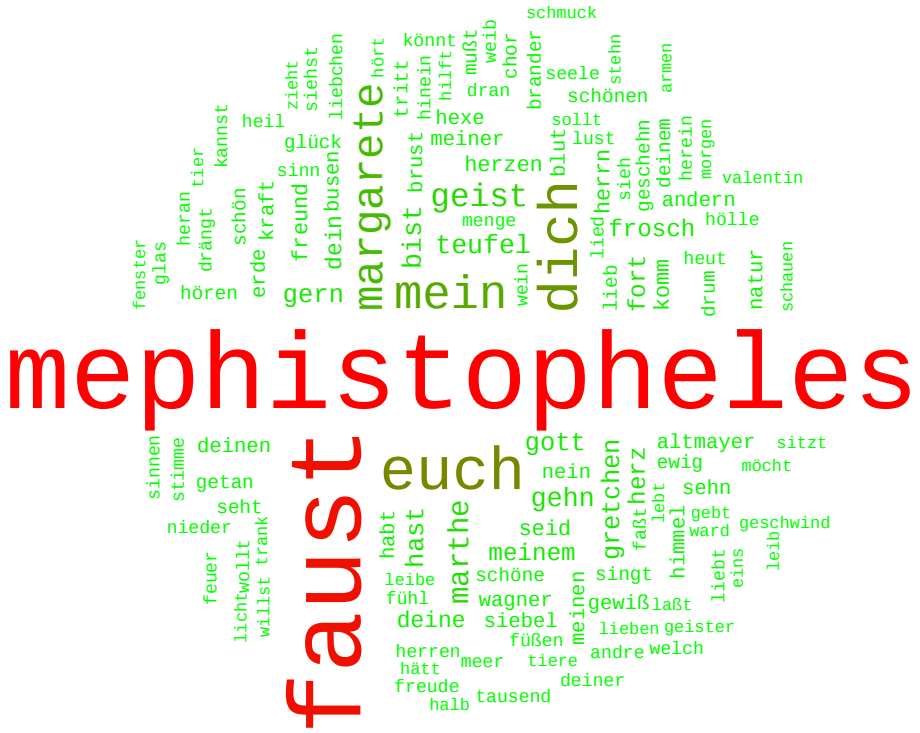

Am Anfang werden alle Wörter zufällig in einem Kreis ausgerichtet (das häufigste Wort in der Mitte), anschließend wird in absteigender Häufigkeit getestet, ob sich das Wort mit einem bereist gespeicherten überschneidet. Tritt dieser Fall ein (was fast immer passiert), wird entlang eine Spirale (siehe Abbildung) eine Position ohne Überschneiden gefunden.

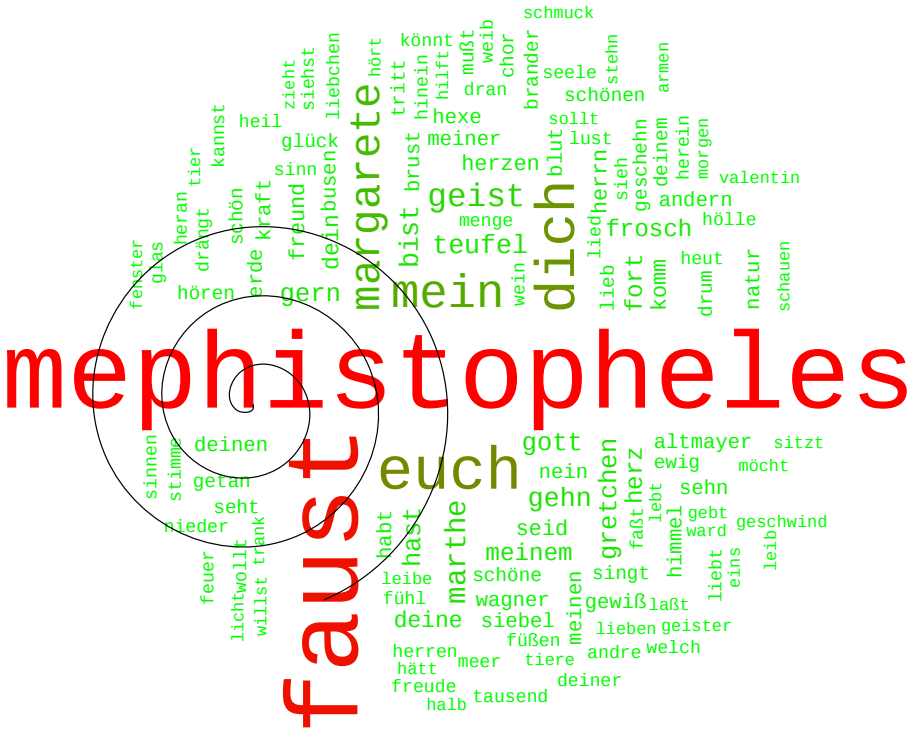

Problematisch an der Vorgehensweise sind die ständigen Kollisionstests zwischen Wörtern (die als Rechtecke behandelt werden), in der Implementierung wird dabei noch ein recht einfaches Durchtesten benutzt, besser wäre hier der Einsatz eines Quadtrees oder R-Trees.

6 Offen

Z.b. die Anforderung (A), zusätzliche Anforderungen (Kommentare ignorieren,...), bessere Kollisionstests. Andere Ausgabe'plugins', z.B. gravitationsbasierend, sternförmig, hierarchisch. Während der Tests in der Entwicklung wurde auch probiert ein 3 GB Wikipedia Dump File zu analysieren, das ist aber leider nur mit ausreichend Hauptspeicher möglich, diese Problem könnte man Lösen in dem man die Eingabedatei, falls sie größer als irgendeine Grenze, stückchenweise analysiert und die Hisotgramme der einzelnen Analysen dann zusammenfügt.