

# Automatische Prüfung von Wikipedia-Artikeln

WikiCon 2013  
23.11.2013

Daniel Naber



# Überblick

- Worum geht es hier (nicht)?
- Fehlerbeispiele
- Überblick LanguageTool
- LanguageTool Funktionsprinzip
- Fehlermuster
- LanguageTool und Wikipedia

# Daniel Naber

- Entwickler von LanguageTool
  - Umfrage: Wer kennt LanguageTool schon?
- Entwickler von OpenThesaurus
  - Umfrage: Wer kennt OpenThesaurus?



# Worum geht es hier nicht?

- Einfache Rechtschreibprüfung
- Prüfung MediaWiki-Syntax
- Prüfung von Textformatierungen (fett, kursiv etc.)
- Bot-Programmierung
  - LanguageTool nutzt die Wikipedia-API und die XML-Dumps

# Worum geht es hier?

- Automatische Prüfung von:
  - Rechtschreibung - mit Beachtung des Kontext
  - Stil
  - Grammatik

# Grundidee

- Da anfangen, wo die klassische Rechtschreibprüfung aufhört
  - klassische Rechtschreibprüfung: prüft einzelne Wörter, ohne Kontext zu beachten

Finde die Fehler:

Berthold Brecht ist tod?  
Das kann nicht seien!

Berthold Brecht ist tot? Das kann nicht sein!



**Berthold** Brecht ist tod? Das kann nicht seien!

**Meinen Sie den deutschen Dramatiker 'Bertolt' Brecht? (Das ist die von ihm selbst bevorzugte Schreibweise des Vornamens.)**

Bertolt

Hier ignorieren

Fehler dieses Typs ignorieren

# LanguageTool: Überblick

- Open Source Stil- und Grammatikprüfung
- unterstützt 29 Sprachen, darunter Deutsch, Englisch, Französisch, Spanisch
- seit 2003
- Lizenz: LGPL
- nicht Wikipedia-spezifisch, aber gut für die Wikipedia nutzbar
- Homepage: <http://languagetool.org>

# LanguageTool: Prinzip

- Text wird analysiert: Erkennung Satzgrenzen, Wortarten
  - „Hauses“: Nomen, Neutrum, Singular, Genitiv
- Text wird auf Fehlermuster durchsucht
  - LanguageTool kennt keine Grammatik, es kennt Fehler

# Fehlermuster-Beispiel (vereinfacht)

```
<rule>  
  <pattern>  
    <marker>  
      <token>Berthold</token>  
    </marker>  
    <token>Brecht</token>  
  </pattern>  
  <message>Meinen Sie den deutschen Dramatiker  
    <suggestion>Bertolt</suggestion> Brecht?  
  </message>  
</rule>
```

Berthold Brecht ist tot.

# Fehlermuster (1)

- Reguläre Ausdrücke:  
`<token regexp="yes">Berth?old</token>`
- Wortarten ansprechen, z.B. alle Verben:  
`<token postag_regexp="yes"  
 postag="VER:.*">`
- Negation:  
`<token negate="yes">Haus</token>`
- ...und mehr: <http://www.languagetool.org/development/>

# Fehlermuster (2)

- Deutsch: über 1700 Regeln als Fehlermuster
  - Englisch: 900 Regeln
  - Griechisch, Japanisch, Khmer: weniger als 30 Regeln

# Fehlermuster: Grenzen

- Warum war „Brecht“ falsch im ersten Beispiel?

Berthold Brecht ist tod? Das kann nicht seien!

- Komplizierte Regeln in Java programmiert

# Beispielfehler

- Seid gestern geht es mir besser.
- Das Ganze ist größer wie die Summe seiner Teile.
- Zertifiziert gemäß des aktuellen Standards.
- in Mühlheim an der Ruhr
- Sein Verhalten spiegelt seine Haltung wieder.
- Ich hatte eine Mittelohrenzündung.



# Beispielfehler - mit Korrektur

- Seid **d** gestern > Seit gestern
- größer **wie** > größer als
- gemäß **des** > gemäß dem
- Mü**h**lheim an der Ruhr > Mülheim an der Ruhr
- spiegelt ... **wie**der > spiegelt ... wider
- Mittelohre**n**zündung =  
Mittel + Ohren + Zündung >  
Mittelohrentzündung

# Wikipedia-spezifisches

- „seit Kurzem“ > relative Zeitangaben
- Wikipedia: Vermeide hohle Phrasen
  - „entgegen landläufiger Meinung“
  - „viele Wissenschaftler sagen“

# LanguageTool und Wikipedia

- Fehlersammlung:  
<http://community.languagetool.org/corpusMatch> (aus dem Wikipedia-XML-Dump)
- Einzelne Seite prüfen:  
<http://www.languagetool.org/wikicheck/>  
auch mit Bookmarklet

# Fehlermuster selber schreiben

- <http://www.language-tool.org/ruleeditor/>
  - prüft gegen 500.000 Sätze aus der Wikipedia
  - Advanced mode:  
Beispiel/Testsätze im XML

# TODOs und Ideen

- Firefox-Plugin
  - kennt Mediawiki-Syntax nicht
  - nach Chrome portieren
- mehr Wikipedia-spezifische Regeln
- mehr Regeln (alle Sprachen)
- täglich alle Wikipedia-Änderungen prüfen?
- siehe  
<http://wiki.languagetool.org/missing-features>

# Mitwirkende gesucht!

- Keine Programmierkenntnisse nötig
- Interesse?
  - mich hier ansprechen oder
  - auf der Mailing-Liste anmelden

<http://languagetool.org>

# Zusammenfassung

- LanguageTool macht da weiter, wo die Rechtschreibprüfung aufhört
- LanguageTool hat mehrere Tools, um die Wikipedia zu prüfen
- Man kann ohne Programmierkenntnisse neue Fehlermuster schreiben
- **Mitwirkende gesucht!**

Vielen Dank!

Fragen?