Tübix 2019

Webcrawling mit Scrapy und PostgreSQL backend

06. Juli 2019

Janek Schoffit

Lightning talk

ZIEL

Ziel

- Open source stack
- Einfach skalierbar
- Erweiterbarkeit

SCRAPY

Scrapy

- Open source web spider framework
- Erweiterbar durch Plugins und Python libs
- Mit scrapyd als daemon deploybar

Scrapy

- Einfache Link extraction per regex
- Mächtiger Parser
- `scrapy-rotating-proxy` plugin

API

API

- REST API
  - Gin Gonic web framework
- Upload der crawler Daten
- Suchanfragen der Website

POSTGRESQL

PostgreSQL

- Relationale Datenbank
- JSON Felder mit Indexierung
- Fulltext search support
  - Vektor Spalte für schnelles Durchsuchen

AUFBAU

Aufbau

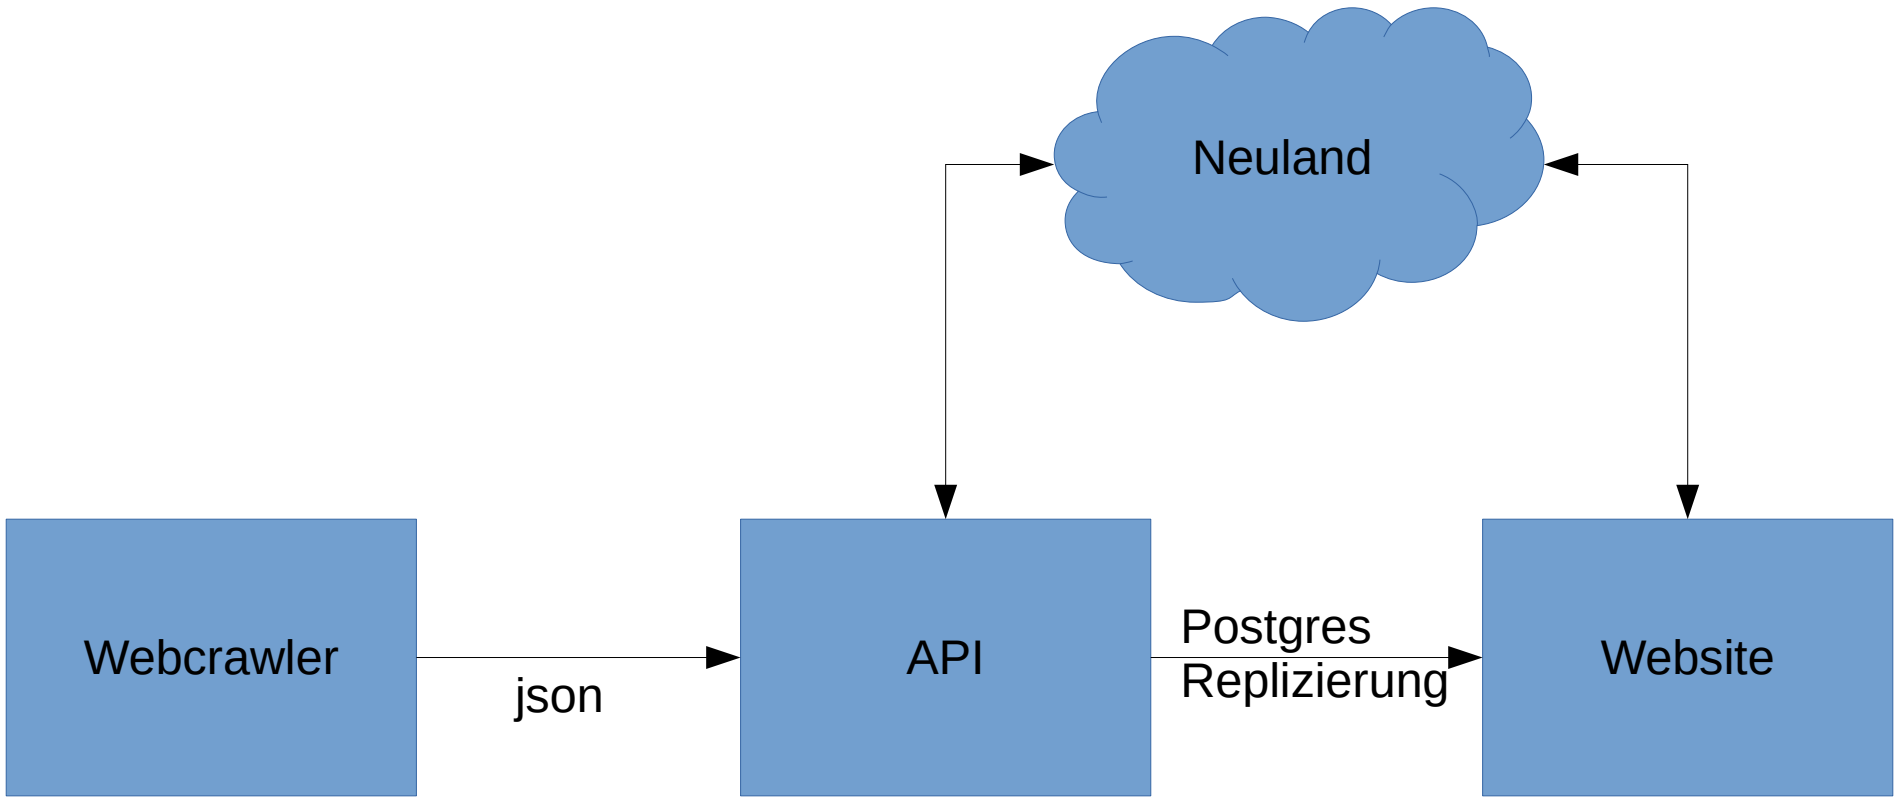

- scrapyd
  - Site 1
  - Site 2

- API
- PostgreSQL

- Website
- Postgres Replik

PEACE OUT!