Od nieustrukturyzowanych danych do przeszukiwalnego korpusu bogatego w metadane:

Skyscraper, P4, Smyrna

Daniel Janus

Rebased

Zdrapywanie danych (*webscraping*)

http://wybory2010.pkw.gov.pl/geo/pl/000000.html

Zbiorcze informacje o				
Województwo	Liczba			
	mieszkańców	wyborców	obwodów	okręgów wyborczych do sejmików
dolnośląskie	2 843 421	2 337 575	1 818	5
kujawsko-pomorskie	2 052 876	1 649 619	1 398	6
lubelskie	2 180 567	1 754 908	1 803	5
lubuskie	1 004 112	810 168	664	5
łódzkie	2 514 380	2 067 733	1 713	6
małopolskie	3 256 359	2 617 323	2 279	6

Zdrapywanie danych (*webscraping*)

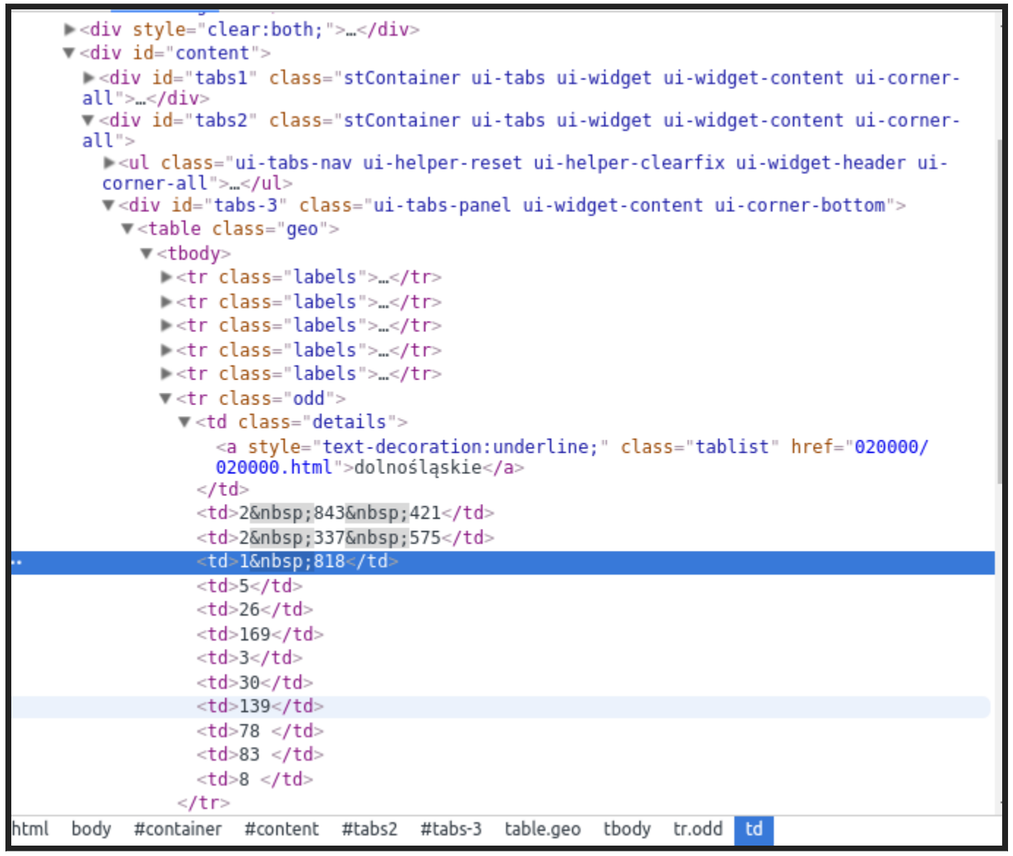

Jak zdrapywać?

```
$ wget -r http://www.strona-z-danymi.pl
$ find . -name '*.html' -exec perl extract.pl {} \;
```

- To nie jest dobry pomysł
  - Nie wszystkie strony wchodzące w skład witryny mają taką samą strukturę
  - `wget` może pobrać za dużo albo za mało; strony mogą się powtarzać
  - Informacja o tym, w którym miejscu witryny jesteśmy, jest semantycznie cenna i nie należy jej gubić

Jak zdrapywać? (2)

```
def scrape_main_page():
  r = requests.get("http://strona-z-danymi.pl")
  data = r.text
  soup = BeautifulSoup(data)
  for link in soup.find_all('a'):
    scrape_subpage(link.get('href'))

def scrape_subpage(url):
  # itd., itp.
```

- Lepiej, ale wciąż nieidealnie
  - Dużo powtarzającego się, technicznego kodu
  - Obsługa błędów, ponawianie prób pobrania, lokalne kopie stron, format wyjściowy, …
  - Każda witryna jest inna i wymaga innych sztuczek

Skyscraper

https://github.com/nathell/skyscraper

- Biblioteka w języku Clojure ułatwiająca tworzenie “zdrapywaczy”
- Bazuje na bibliotece Enlive
- Wyrosła organicznie z “szytych na miarę” programów do pobierania danych z różnych witryn
- Obsługuje szczegóły techniczne pobierania i parsowania danych
- Udostępnia abstrakcje pozwalające skupić się na wyłuskiwaniu danych ze stron WWW

Clojure

- Lisp na platformę JVM
- Typy danych:
  - liczby `42`, napisy `"IPI PAN"`, symbole `foo`, klucze `:foo`, wartości logiczne `:true`
  - listy `(1 2 3)`, wektory `[1 2 3]`, mapy `{:k1 v1, :k2 v2}`, zbiory `#{1 2 3}`
- Kod składa się ze struktur języka
- `(f arg1 arg2)` oznacza “wywołaj funkcję `f` z argumentami `arg1` i `arg2`”

Skyscraper: spostrzeżenia i abstrakcje

- Pobieranie danych ma strukturę drzewiastą
- Różne węzły drzewa są przetwarzane w różny sposób
- W każdym węźle pobieramy nowe informacje
- W każdym węźle znamy ścieżkę, którą do niego dotarliśmy, oraz informacje zebrane z węzłów nadrzędnych
- **Kontekst:** mapa zawierająca “zdrapane dotychczas dane”
- **Procesor:** fragment kodu odpowiedzialny za przetwarzanie konkretnego typu węzłów
  - Funkcja (kontekst, sparsowany HTML) → lista nowych kontekstów

Skyscraper: przykład

http://miejski.pl

```
(defn seed []
  (for [x (concat (map str (char-range \a \z)) ["0-9" "inne"])]
    {:letter x,
     :url (format "http://www.miejski.pl/%s-0.html" x),
     :processor :letter}))

(defprocessor letter
  :cache-template "miejski/:letter/1"
  :process-fn (fn [res ctx]
                (for [a (select res [:div#strony :a])]
                  {:page (text a),
                   :url (href a),
                   :processor :page})))
```

Skyscraper: przykład

http://miejski.pl

```
> (seed)
({:letter "a", :url "http://www.miejski.pl/a-0.html", :processor :letter}
 {:letter "b", :url "http://www.miejski.pl/b-0.html", :processor :letter}
 ; … etc.
 {:letter "inne", :url "http://www.miejski.pl/inne-0.html", :processor :letter})
```

```
> (first (scrape :seed))
{:letter "a", :page "1", :word "A  A   A   sie naebaem",
 :type :summary, :value "Zwrot używany przez ludzi po spożyciu alkoholu."}     ;
```

- `scrape` zwraca leniwą sekwencję liści-kontekstów

Skyscraper: pamięć podręczna

- Dwa rodzaje pamięci podręcznej
  - Pamięć podręczna surowych dokumentów (*HTML cache*)
  - Pamięć podręczna przetworzonych dokumentów (*processed cache*)
- Obie domyślnie włączone, ale można je wyłączyć
- Hierarchiczne klucze
- Implementacje:
  - System plików (domyślna)
  - Jednoplikowa baza danych typu *key-value store* (MapDB; `skyscraper-cache-mapdb`)
  - Pamięć RAM

Skyscraper: pozostałe cechy

- `scrape-csv`
- Uaktualnienia: dowolny procesor można oznaczyć jako `:updatable true`; wtedy uruchomienie Skyscrapera w trybie uaktualnień pobierze odpowiednie strony jeszcze raz, nawet jeśli były już w pamięci podręcznej
- Zawężanie danych: w parametrze `only` można podać okrojony fragment kontekstu

```
> (first (scrape :seed :only {:letter "e"}))
{:letter "e", :page "1", :word "E-faj", :type :summary,
 :value "Skrót od e-papierosa. Używane głównie przez palaczy. Rozwinięcie
         skrótu(potocznie): elektroniczny fajek."}
```

Polish Parliamentary Proceedings Processor (P4)

- Zestaw zbiorów danych pozyskanych z witryny Sejmu RP
  - Dane o posłach (kadencje I-VIII)
  - Wyniki głosowań (*roll-call*; kadencje I-VIII)
  - Stenogramy sejmowe (kadencje I-VIII) z metadanymi
- Także: oparty o bibliotekę Skyscraper program do pobierania i przebudowywania tych danych
- Półautomatyczna weryfikacja i korekcja błędów
- Uaktualniany na bieżąco

P4: schemat działania

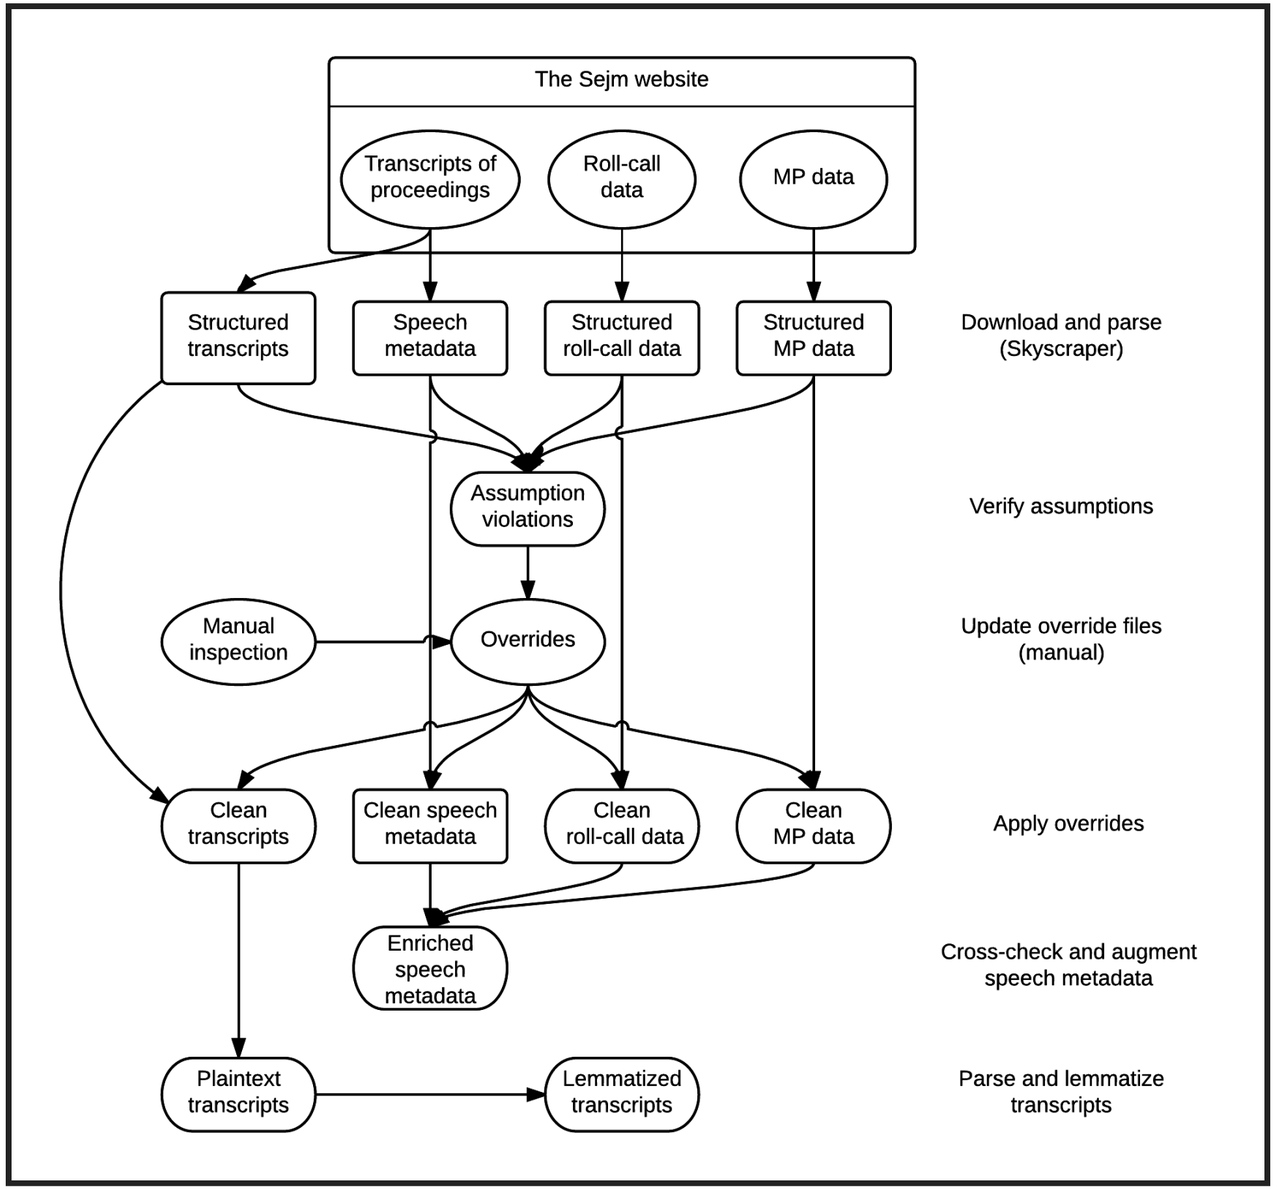

P4: formaty danych

- Dane o posłach: CSV
- Wyniki głosowań: CSV
  - Dla każdej kadencji: macierz *głosowania* ✕ *posłowie*
  - Dodatkowo dla każdego głosowania: przynależność partyjna głosującego
  - Metadane w osobnym pliku
- Stenogramy:
  - HTML (wyczyszczony i wewnętrznie poprawnie skroslinkowany)
  - Czysty tekst
  - Czysty tekst, zlematyzowany
  - Metadane w osobnym pliku CSV

P4: metadane stenogramów

```
<meta content="56" name="POS">
<meta content="3" name="DZIEN">
<meta content="17-12-2009" name="DATA">
<meta content="149" name="WYP">
<meta content="Sekretarz Stanu w Ministerstwie Spraw Wewnętrznych
               i Administracji Tomasz Siemoniak" name="KTO">
<meta content="21" name="PUNKT">
<meta content="Sprawozdanie Komisji Administracji i Spraw Wewnętrznych o stanowisku Sen
               w sprawie ustawy o uregulowaniu stanu prawnego niektórych nieruchomości
               pozostających we władaniu Polskiego Autokefalicznego Kościoła Prawosławn
               (druki nr 2572 i 2580)." name="TYTUL">
```

- Wzbogacone o przynależność partyjną mówcy
  - W kadencjach 1-2: z danych o posłach (na koniec kadencji)
  - W kadencjach 3-8: z danych o głosowaniach (w momencie wypowiedzi)

P4: śmieci w danych

1 kadencja, 6 posiedzenie, 1 dzień, wypowiedź 17, poseł Witold Gadomski:

```
<P>    ´Przyjąć ustawę o prowizorium budżetowym na okres
od dnia 1 stycznia do 31 ▓-iFÖ-ÐYÍòkDñ▪ů╤J&#9632;30-
marca 1992 r. w brzmieniu przedłożenia rządowego z następującymi poprawkami:</P>
```

- Wykrywalne automatycznie
  - Czy w dokumencie występują niestandardowe tagi HTML?
  - Czy występują bardzo długie słowa?
  - Czy występują słowa zawierające znaki niełacińskie?
- Ręcznie utrzymywany plik poprawek (offsety znaków do wycięcia)

P4: niespójności

1 kadencja, 36 posiedzenie, 2 dzień, wypowiedź 34:

```
<meta content="Poseł Wojciech Arkuszewski" name="KTO">

…

<P><B><FONT SIZE="+1">Poseł Maciej Manicki</FONT></B></P>
<P>    Panie Marszałku! Wysoka Izbo! Sojusz Lewicy Demokratycznej generalnie popiera
```

- Ręcznie rozstrzygnięte na podstawie analizy wystąpienia przewodniego marszałka

P4: niespójności

1 kadencja, 27 posiedzenie, 1 dzień, wypowiedź 14:

```
<meta content="Poseł Tadeusz Kowalczyk" name="KTO">
```

- Który to z dwóch posłów o tym imieniu i nazwisku (w większości odróżnialnych po imieniu ojca)?

1 kadencja, 14 posiedzenie, 4 dzień, wypowiedź 56:

```
<meta content="Poseł Andrzej Kamiński" name="KTO">
```

- Nie było takiego posła
- Częsta wariantywna pisownia nazwisk: *Edward Müller/Muller*, *Halina Nowina-Konopka/Nowina Konopka*, *Piotr Van/van der Coghen*

Smyrna

PROSTY KONKORDANCER OBSŁUGUJĄCY JĘZYK POLSKI

Polikarp ze Smyrny (ok. 70–156)

Smyrna 0.1 (2011)

- Konkordancer dla języka polskiego pozwalający na łatwe tworzenie własnych korpusów
- Obsługa dokumentów w formacie HTML
- Maksymalna prostota użytkowania
  - *Nieekspresywny* język zapytań
  - Odbiorcy: użytkownicy nietechniczni, nielingwiści
- Prezentacja dokumentów w ich oryginalnej postaci
- Analiza morfologiczna na bieżąco
- Generowanie list frekwencyjnych

Smyrna: tworzenie korpusu

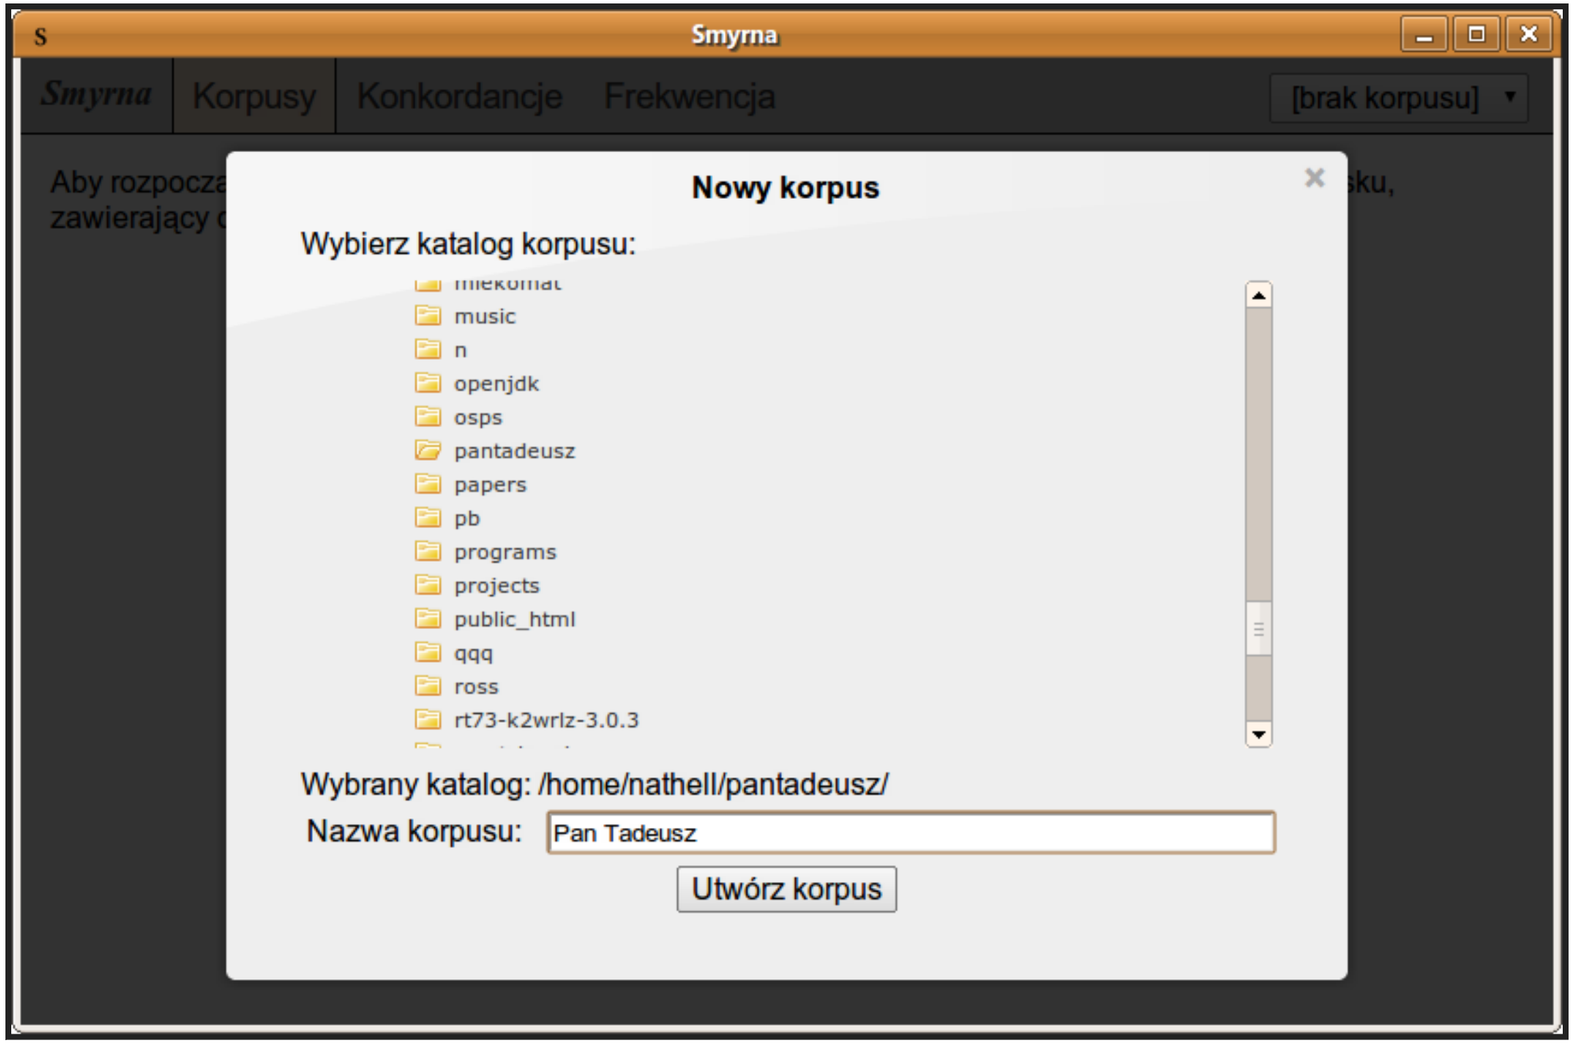

Smyrna: lista korpusów

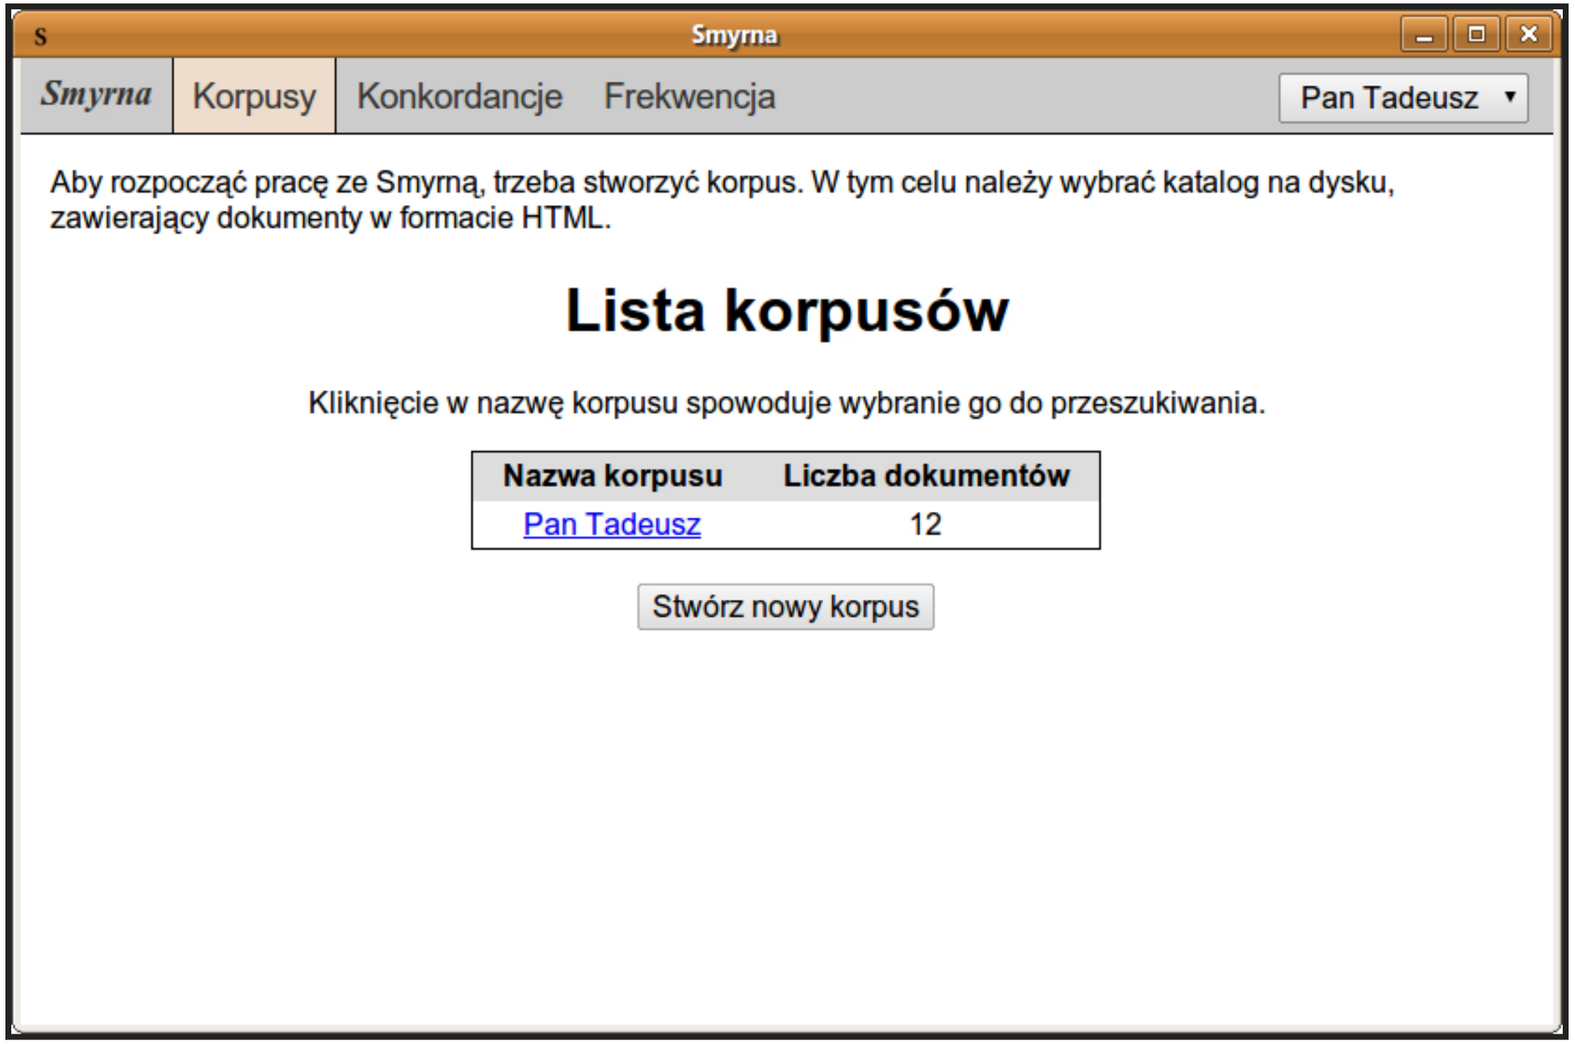

Smyrna: wyszukiwanie

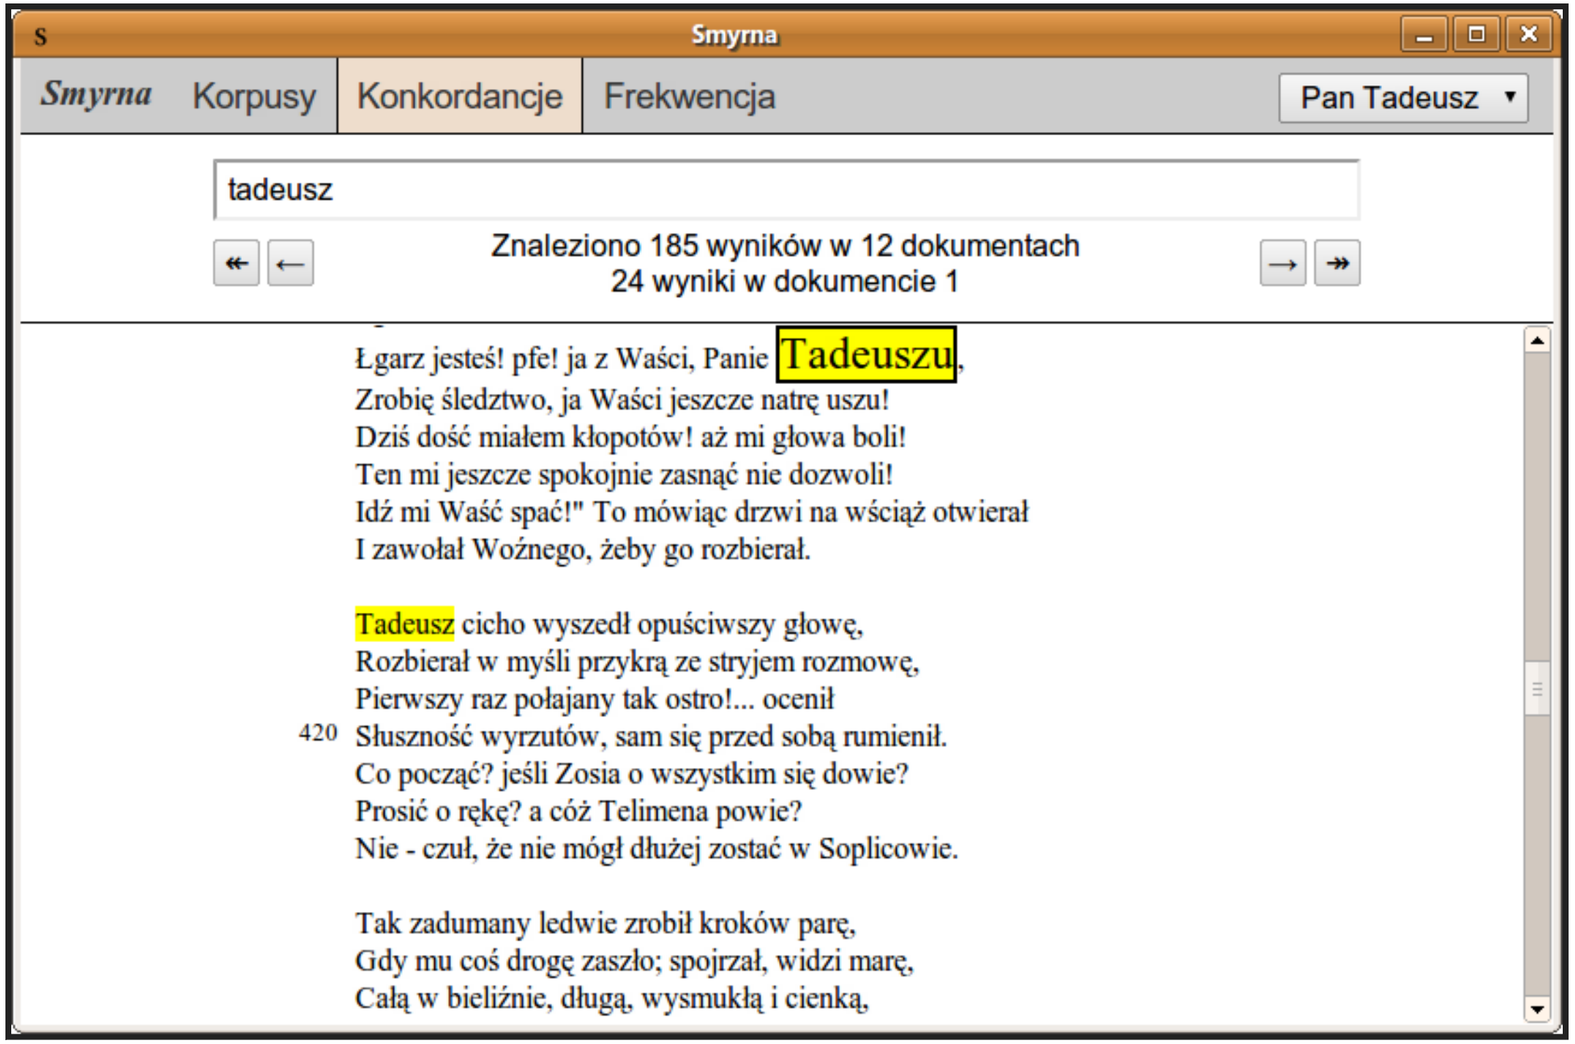

Smyrna: lista frekwencyjna

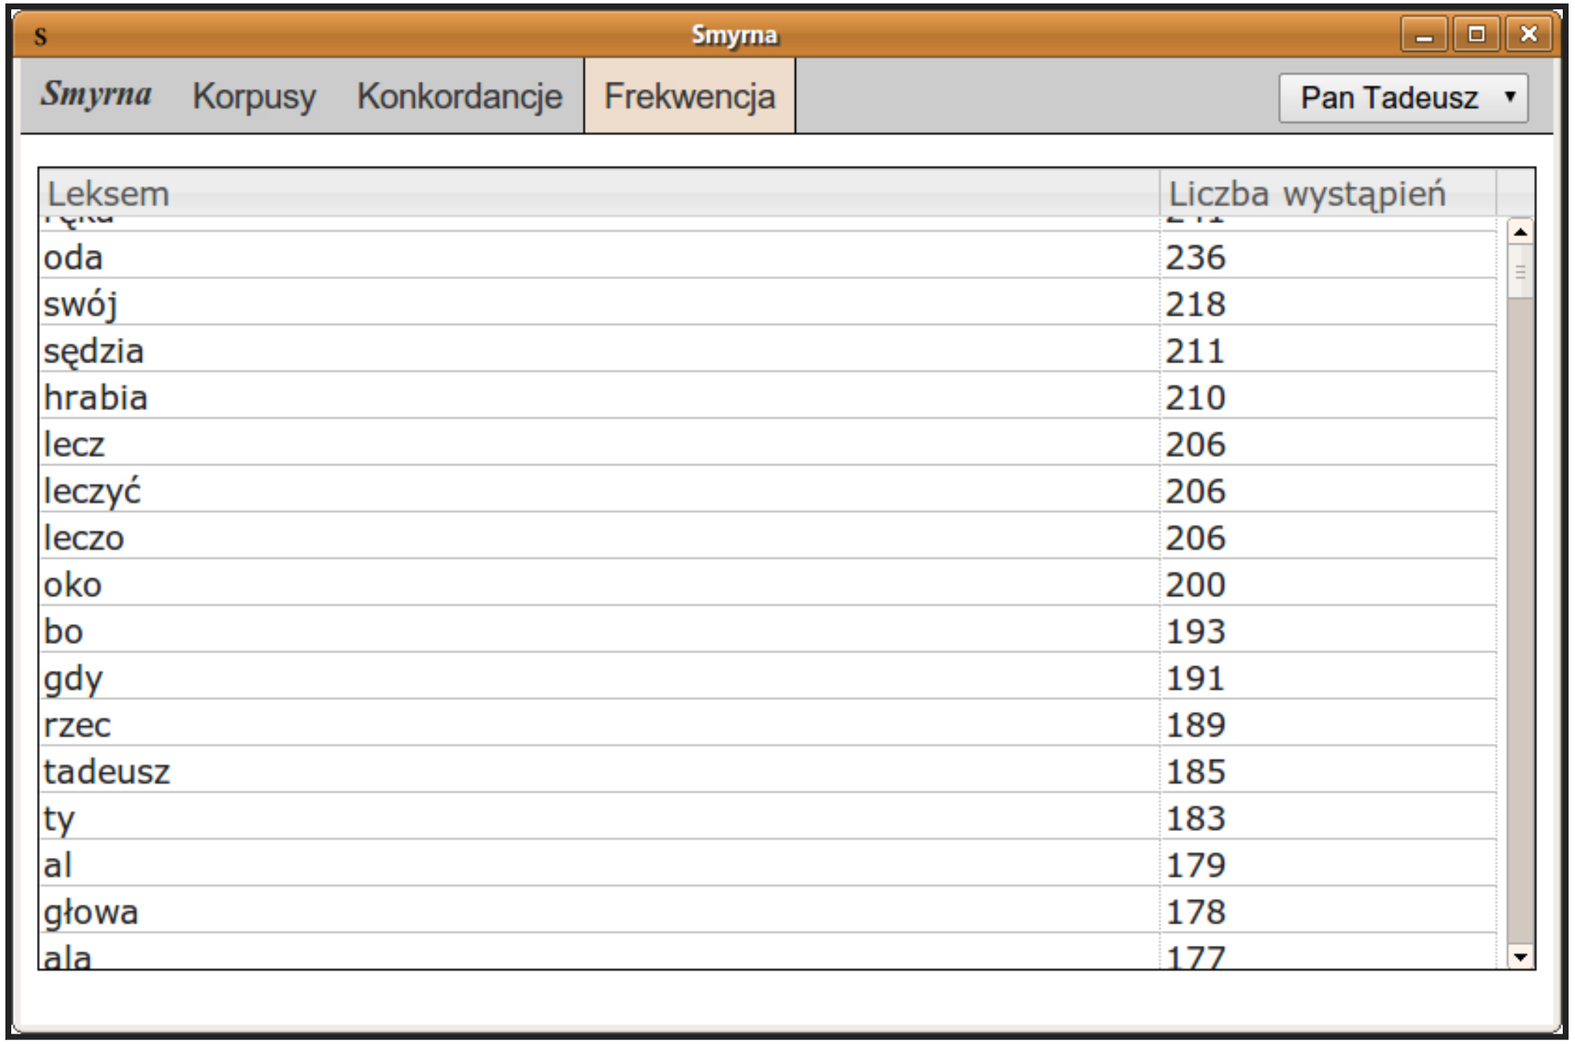

Smyrna 0.3 (2016)

- Obsługa korpusów bogatych w metadane
- Obsługa sporych korpusów (P4: ok. 280 tys. dokumentów, ok. 200 mln słów)
- Tworzenie obszarów z filtrów i wyszukiwanie tylko w obszarach
  - `within` z Poliqarpa na sterydach
- Porównania obszarów
- Język zapytań nadal nieekspresywny
- Nowy, zwarty, binarny format korpusu, inspirowany Poliqarpem
  - Jeden plik!

Smyrna 0.3: technicznie

- Aplikacja webowa, działająca lokalnie na komputerze użytkownika
- Backend: Clojure
- Interfejs użytkownika: ClojureScript (Reagent)
  - Poprzednie wersje: CoffeeScript + Backbone.js
- Ok. 1200 linii kodu
- Przepisana w zasadzie od zera

Lematyzacja

- Lematyzator unigramowy, wytrenowany na milionowym podkorpusie NKJP
- Jeśli nie ma w częstościach NKJP: najczęstsza forma podstawowa z Morfologika (PoliMorf)
- Wydzielona biblioteka do lematyzacji (Polelum)
- Może kiedyś: prawdziwe tagowanie (Pantera?)

Format korpusu

- Pojedynczy plik ZIP *bez kompresji*
  - Można `mmap`ować poszczególne kawałki pliku
- Główny element: obraz korpusu (`image`)
  - Zawiera *sparsowane dokumenty HTML*, zserializowane i skompresowane kanonicznym kodem Huffmana
  - Rozmiar alfabetu: ok. 500 000 symboli
  - Rodzaje symboli: tekst, tag otwierający, atrybut HTML, wartość atrybutu, symbol NOSPACE
- Pozostałe elementy: słowniki (w formacie CFSA2 morfologik-stemming), pliki offsetów, dane do dekompresji, indeks odwrotny

DEMO

DZIĘKUJĘ!

Daniel Janus
Rebased

https://github.com/nathell/skyscraper
http://smyrna.danieljanus.pl