

Wstępna wersja języka zapytań w nowym Poliqarpie

Dominika Pawlik, Aleksander Zabłocki

MIM UW, IPI PAN

Bartosz Zaborowski

IPI PAN

21 października 2013

Plan

- 1 Co chcemy zrobić
- 2 Model danych
- 3 Przegląd języka

Plan

- 1 Co chcemy zrobić
 - Zarys możliwości
 - Trochę szczegółów
- 2 Model danych
- 3 Przegląd języka

Wejście

Poliquarp 1.0 & 2.0

- KIPI (NKJP)
 - morfoskładnia
 - segmentacja
 - metadane

Poliquarp 2.0

- całe NKJP
 - sł. składniowe, jedn. nazewn.
 - sensy słów
- inne projekty IPI
 - Składnica: **grafy** składnikowe
 - **grafy** zależnościowe
 - LFG
- możliwe rozszerzenia
 - korpusy historyczne
 - atrybuty czcionki
 - jakość OCR, transkrypcje
 - atrybuty pozycyjne

Funkcjonalność

(klamerki = świat wyszukiwarek drzewiastych)

Poliqarp 1.0 & 2.0

- wieloznaczność
 - interpretacji

Poliqarp 2.0

- grafu składnikowego
- segmentacji
- transkrypcji
- ...

nietypowe

- wyrażenia regularne
 - dla znaków
 - dla segmentów

- relacje „drzewiaste”
 - ojciec, przodek
 - lewy brat, lewy syn

standard


- zmienne
 - lukier składniowy dla typów skończonych

- kwantyfikacja
- negacja


ambitne

Grafy składniowe

- współdzielone węzły
- nieciągłość poddrzew



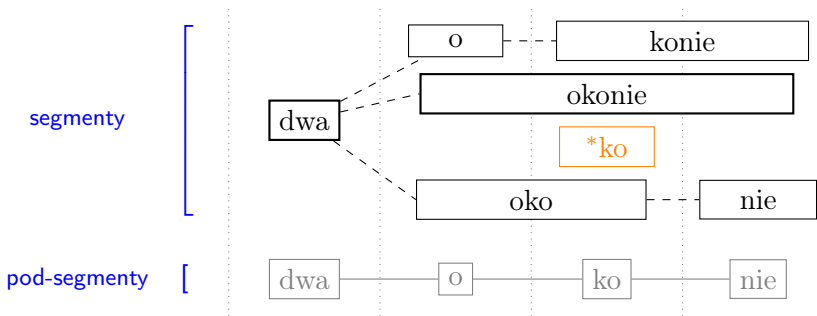
- zaburzenia kolejności:



- porządek **segmentowy** — dla wszystkich segmentów
- porządki **krawędziowe** — dla dzieci dowolnego węzła

Wieloznaczna segmentacja

wejście: d w a o k o n i e



- segmenty = DAG z rzutowaniem do ciągu pod-segmentów
- tylko jedna ścieżka (np. dwa okonie) podlega pełnej anotacji

Plan

- 1 Co chcemy zrobić
- 2 Model danych
 - Typy danych
 - Modelowanie NKJP
 - Założenia
- 3 Przegląd języka

Typy danych

- Typ prosty
 - integer, float
 - Boolean
 - string, enum (np. wartość kategorii gramatycznej)
- Struktura atrybutowa
 - ▶ np. węzeł; krawędź; interpretacja; struktura LFG; czcionka
 - ▶ przykładowa specyfikacja: `[orth = bym && !space]`
- Lista
 - ▶ np. segmentów w zdaniu; dzieci danego węzła; `{ gen, acc }`
- Lista wieloznaczności: elementy **wybrane** oraz **niewybrane**
 - ▶ np. interpretacje; transkrypcje; zestawy dzieci węzła
 - ▶ przykładowe użycie: `[msd ~ [pos = subst]]`
 - ▶ **nie jest** listą, raczej parą list (wybrane, niewybrane)

Rodzaje struktur

- wyróżnione typy struktur: węzły i krawędzie

węzły	zwykłe struktury (np. LFG)
<ul style="list-style-type: none">• tworzą DAG• połączone krawędziami• \rightsquigarrow fragmenty wejścia	<ul style="list-style-type: none">• tworzą dowolny graf• połączone atrybutami• \curvearrowright fragmenty wejścia

Rodzaje struktur

- wyróżnione typy struktur: **węzły** i **krawędzie**

węzły	zwykłe struktury (np. LFG)
<ul style="list-style-type: none">tworzą DAGpołączone krawędziami\rightsquigarrow fragmenty wejścia	<ul style="list-style-type: none">tworzą dowolny grafpołączone atrybutami\rightsquigarrow fragmenty wejścia

- dwa rodzaje krawędzi (jak np. w ANNIS)

krawędzie pierwotne	krawędzie wtórne
zastosowanie: składnia	zastosowanie: koreferencje
<ul style="list-style-type: none">tworzą DAGlokalnegęste	<ul style="list-style-type: none">tworzą dowolny grafnieograniczonerzadkie (?)

Atrybut typu

Specjalny atrybut dla dowolnych struktur

- konfigurowalna nazwa — u nas `type`
- wartości: `node`, `edge`, `interp`, `fstr`, ...

Atrybut typu

Specjalny atrybut dla dowolnych struktur

- konfigurowalna nazwa — u nas `type`
- wartości: `node`, `edge`, `interp`, `fstr`, ...

- **zagnieżdżanie**

- ciąg podtypów:
- dowolna grupa składniowa:

```
node:syngr:NG:PrepNG
```

```
[type = ".*:syngr:.*"]
```

- **lukier składniowy:**

```
[type = syngr/t] , [syngr]
```

Typy danych w praktyce – przykład NKJP

Uwagi na początek:

- to tylko przykład reprezentacji NKJP za pomocą dostępnych typów,
- nie należy się zbyt przywiązywać do nazw (np. atrybutów),
- decyzje o sposobie reprezentacji należą do osoby przygotowującej korpus dla Poliqarpa,
- w zależności od potrzeb ten sam korpus może być różnie zamodelowany!

Typy danych w praktyce – przykład NKJP

Uwagi na początek:

- to tylko przykład reprezentacji NKJP za pomocą dostępnych typów,
- nie należy się zbyt przywiązywać do nazw (np. atrybutów),
- decyzje o sposobie reprezentacji należą do osoby przygotowującej korpus dla Poliqarpa,
- w zależności od potrzeb ten sam korpus może być różnie zamodelowany!

Segmentacja

- Segmenty reprezentujemy przez węzły z `type = node:seg`.
- Reprezentacja DAGu segmentacji w NKJP uboga, ale można ją zamodelować:
 - węzły z `type = node:sub` – najdłuższe niepodzielne ciągi znaków (podsegmenty),
 - atrybuty `text`, `newword`, `newline`, `endword` itp,
 - krawędzie wtórne* z segmentów do podsegmentów.
- W segmentach również atrybuty `text`, `newword`, `endword` (na podstawie podsegmentów).

Segmentacja

- Segmenty reprezentujemy przez węzły z `type = node:seg`.
- Reprezentacja DAGu segmentacji w NKJP uboga, ale można ją zamodelować:
 - węzły z `type = node:sub` – najdłuższe niepodzielne ciągi znaków (podsegmenty),
 - atrybuty `text`, `newword`, `newline`, `endword` itp,
 - krawędzie wtórne* z segmentów do podsegmentów.
- W segmentach również atrybuty `text`, `newword`, `endword` (na podstawie podsegmentów).

Segmentacja

- Segmenty reprezentujemy przez węzły z `type = node:seg`.
- Reprezentacja DAGu segmentacji w NKJP uboga, ale można ją zamodelować:
 - węzły z `type = node:sub` – najdłuższe niepodzielne ciągi znaków (podsegmenty),
 - atrybuty `text`, `newword`, `newline`, `endword` itp,
 - krawędzie wtórne* z segmentów do podsegmentów.
- W segmentach również atrybuty `text`, `newword`, `endword` (na podstawie podsegmentów).

Segmentacja

- Segmenty reprezentujemy przez węzły z `type = node:seg`.
- Reprezentacja DAGu segmentacji w NKJP uboga, ale można ją zamodelować:
 - węzły z `type = node:sub` – najdłuższe niepodzielne ciągi znaków (podsegmenty),
 - atrybuty `text`, `newword`, `newline`, `endword` itp,
 - krawędzie wtórne* z segmentów do podsegmentów.
- W segmentach również atrybuty `text`, `newword`, `endword` (na podstawie podsegmentów).

Morfoskładnia

- Dodatkowe atrybuty węzłów `node:seg` :
- `orth` - jak w NKJP,
- `msd` - lista wieloznaczności, w niej struktury atrybutowe:
 - `type = morph`,
 - `base`,
 - tag zakodowany pozycyjnie (`pos`, `case`, ...)
- na liście `msd` dokładnie jedna wartość wybrana.

Morfoskładnia

- Dodatkowe atrybuty węzłów `node:seg:`
- `orth` - jak w NKJP,
- `msd` - lista wieloznaczności, w niej struktury atrybutowe:
 - `type = morph`,
 - `base`,
 - tag zakodowany pozycyjnie (`pos`, `case`, ...)
- na liście `msd` dokładnie jedna wartość wybrana.

Morfoskładnia

- Dodatkowe atrybuty węzłów `node:seg` :
- `orth` - jak w NKJP,
- `msd` - lista wieloznaczności, w niej struktury atrybutowe:
 - `type = morph` ,
 - `base`,
 - tag zakodowany pozycyjnie (`pos`, `case`, ...)
- na liście `msd` dokładnie jedna wartość wybrana.

Morfoskładnia

- Dodatkowe atrybuty węzłów `node:seg` :
- `orth` - jak w NKJP,
- `msd` - lista wieloznaczności, w niej struktury atrybutowe:
 - `type = morph` ,
 - `base`,
 - tag zakodowany pozycyjnie (`pos`, `case`, ...)
- na liście `msd` dokładnie jedna wartość wybrana.

Słowa składniowe

Węzły o typie `node:synw`.

- Atrybuty: `orth`, `newword` itp. - syntezowane ze składowych, `msd` - jak w segmentach (1-elementowa lista wieloznaczności),
- krawędzie pierwotne do składników (segmentów lub słów skł.).

Słowa składniowe

Węzły o typie `node:synw`.

- Atrybuty: `orth`, `newword` itp. - syntezowane ze składowych, `msd` - jak w segmentach (1-elementowa lista wieloznaczności),
- krawędzie pierwotne do składników (segmentów lub słów skł.).

Słowa składniowe

Węzły o typie `node:synw`.

- Atrybuty: `orth`, `newword` itp. - syntezowane ze składowych, `msd` - jak w segmentach (1-elementowa lista wieloznaczności),
- krawędzie pierwotne do składników (segmentów lub słów skł.).

Grupy składniowe

Również węzły...

- `type = node:syngr:<typ_grupy>`,
- syntezowany `orth`,
- krawędzie pierwotne do składników (słów skł. lub grup):
 - `type` dla krawędzi: `head:synh`, `head:semh`, `nonhead`;
 - `head:synh` i `head:semh` mogą wskazywać na ten sam węzeł.

Grupy składniowe

Również węzły...

- `type = node:syngr:<typ_grupy>`,
- syntezowany `orth`,
- krawędzie pierwotne do składników (słów skł. lub grup):
 - `type` dla krawędzi: `head:synh`, `head:semh`, `nonhead`;
 - `head:synh` i `head:semh` mogą wskazywać na ten sam węzeł.

Sensy słów

- Dodatkowy atrybut węzłów `node:seg` – *sense*,
- trochę podobny do `msd`:
 - lista wieloznaczności zawierająca potencjalne tagi sensów (np. `{zostac.1...zostac.5}`),
 - jeden element wybrany,
 - lista pusta dla słów nieanotowanych.

Sensy słów

- Dodatkowy atrybut węzłów `node:seg` – *sense*,
- trochę podobny do `msd`:
 - lista wieloznaczności zawierająca potencjalne tagi sensów (np. `{zostac.1...zostac.5}`),
 - jeden element wybrany,
 - lista pusta dla słów nieanotowanych.

Sensy słów

- Dodatkowy atrybut węzłów `node:seg` – *sense*,
- trochę podobny do `msd`:
 - lista wieloznaczności zawierająca potencjalne tagi sensów (np. `{zostac.1...zostac.5}`),
 - jeden element wybrany,
 - lista pusta dla słów nieanotowanych.

Jednostki nazewnicze

- Struktura składniowa, węzły typu
`node:named:typ_jednostki:podtyp_jednostki`,
- pozostałe atrybuty jednostek jak w korpusie (`base`,
`certainty...`),
- struktura odrębna od słów i grup skł., zbudowana nad segmentami.

Jednostki nazewnicze

- Struktura składniowa, węzły typu
`node:named:typ_jednostki:podtyp_jednostki`,
- pozostałe atrybuty jednostek jak w korpusie (**base**,
certainty...),
- struktura odrębna od słów i grup skł., zbudowana nad segmentami.

Jednostki nazewnicze

- Struktura składniowa, węzły typu
`node:named:typ_jednostki:podtyp_jednostki`,
- pozostałe atrybuty jednostek jak w korpusie (**base**, **certainty...**),
- struktura odrębna od słów i grup skł., zbudowana nad segmentami.

Segmentacja wielkoskalowa

- Zdania: węzły typu `node:s`, krawędzie do grup i/lub słów skł. oraz, niezależnie, do jednostek nazewniczych,
- akapity: węzły z `type = node:p`,
- dokumenty: najwyższy poziom grafu składni; węzły typu `node:doc`,
- dawne metadane są zwykłymi atrybutami dokumentów.

Segmentacja wielkoskalowa

- Zdania: węzły typu `node:s`, krawędzie do grup i/lub słów skł. oraz, niezależnie, do jednostek nazewniczych,
- akapity: węzły z `type = node:p`,
- dokumenty: najwyższy poziom grafu składni; węzły typu `node:doc`,
- dawne metadane są zwykłymi atrybutami dokumentów.

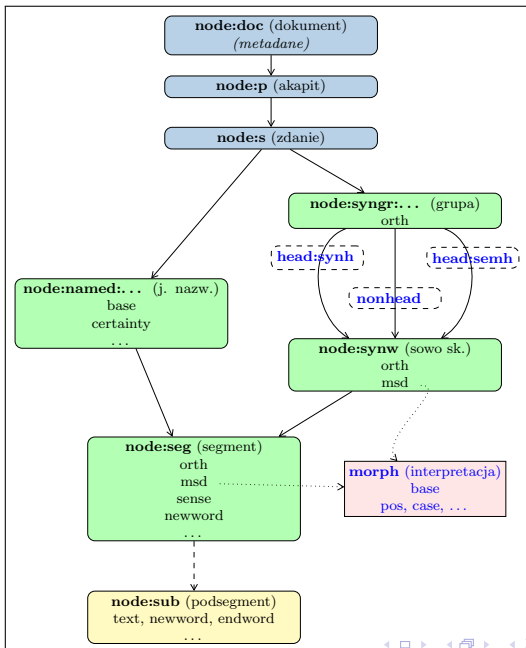
Segmentacja wielkoskalowa

- Zdania: węzły typu `node:s`, krawędzie do grup i/lub słów skł. oraz, niezależnie, do jednostek nazewniczych,
- akapity: węzły z `type = node:p`,
- dokumenty: najwyższy poziom grafu składni; węzły typu `node:doc`,
- dawne metadane są zwykłymi atrybutami dokumentów.

Segmentacja wielkoskalowa

- Zdania: węzły typu `node:s`, krawędzie do grup i/lub słów skł. oraz, niezależnie, do jednostek nazewniczych,
- akapity: węzły z `type = node:p`,
- dokumenty: najwyższy poziom grafu składni; węzły typu `node:doc`,
- dawne metadane są zwykłymi atrybutami dokumentów.

Podsumowanie obrazkowe



Ogólne założenia modelu danych

- Wyróżniamy segmenty = liście w grafie składniowym (patrzmy na krawędzie pierwotne),
- 1 wyróżniony rodzaj segmentacji wielkoskalowej (np. zdania),
- rozróżniamy porządek krawędziowy (dzieci węzła) i segmentowy (wg segmentów, niekoniecznie liniowy),
- struktury atrybutowe mogą być współdzielone (np. f-struktury w LFG).

Ogólne założenia modelu danych

- Wyróżniamy segmenty = liście w grafie składniowym (patrzmy na krawędzie pierwotne),
- 1 wyróżniony rodzaj segmentacji wielkoskalowej (np. zdania),
- rozróżniamy porządek krawędziowy (dzieci węzła) i segmentowy (wg segmentów, niekoniecznie liniowy),
- struktury atrybutowe mogą być współdzielone (np. f-struktury w LFG).

Ogólne założenia modelu danych

- Wyróżniamy segmenty = liście w grafie składniowym (patrzmy na krawędzie pierwotne),
- 1 wyróżniony rodzaj segmentacji wielkoskalowej (np. zdania),
- rozróżniamy porządek krawędziowy (dzieci węzła) i segmentowy (wg segmentów, niekoniecznie liniowy),
- struktury atrybutowe mogą być współdzielone (np. f-struktury w LFG).

Plan

- 1 Co chcemy zrobić
- 2 Model danych
- 3 Przegląd języka**
 - Budowa zapytania
 - Obiekty, relacje, atrybuty
 - Zmienne
 - Inne

Budowa zapytania (część I)

Od szczegółu do ogółu

- Zapytanie egzystencjalne o **wartość**
 - węzeł `[orth = pies]`
 - lista węzłów `[pos = subst]*`
- sukces** \iff znaleziono spacyfikowany(-e) obiekt(-y)

Budowa zapytania (część I)

Od szczegółu do ogółu

- Zapytanie egzystencjalne o **wartość**

- węzeł

[orth = pies]

- lista węzłów

[pos = subst]*

sukces \iff znaleziono spacyfikowany(-e) obiekt(-y)

- Zapytanie **relacyjne**

[type = syngr:NG] > [orth = pies]

sukces \iff sukces w podzapytaniach + zachodzi relacja

Budowa zapytania (część I)

Od szczegółu do ogółu

- Zapytanie egzystencjalne o **wartość**

- węzeł `[orth = pies]`
- lista węzłów `[pos = subst]*`

sukces \iff znaleziono specyfikowany(-e) obiekt(-y)

- Zapytanie **relacyjne**

`[type = syng:NG] > [orth = pies]`

sukces \iff sukces w podzapytaniach + zachodzi relacja

- **Kombinacja logiczna** zapytań

`$X := [pos = subst] && (nie [] $X => $X.case = gen)`

sukces \iff wyrażenie obliczone na wynikach podzapytań daje true

Budowa zapytania (część I)

Od szczegółu do ogółu

- Zapytanie egzystencjalne o **wartość**

- węzeł `[orth = pies]`
- lista węzłów `[pos = subst]*`

sukces \iff znaleziono specyfikowany(-e) obiekt(-y)

- Zapytanie **relacyjne**

`[type = syng:NG] > [orth = pies]`

sukces \iff sukces w podzapytaniach + zachodzi relacja

- **Kombinacja logiczna** zapytań

`$X := [pos = subst] && (nie [] $X => $X.case = gen)`

sukces \iff wyrażenie obliczone na wynikach podzapytań daje true

Morał: **zapytanie** = wyrażenie **konwertowalne** do booleana
(konwertowalne typy: węzeł; lista węzłów; boolean)

Opis obiektów

- Konstruktor (\rightsquigarrow **wartość**) lub **specyfikacja**

typ	konstruktor	specyfikacja
liczba	1 2.5	—
boolean	true false	—
string, enum	pies "\?"	"p(ie)?s(a u ie)?" (wyrażenie regularne)
struktura	—	[orth = kot && !space] (wyrażenie logiczne)
lista	{ nom, gen }	{ [orth = kot]* } (wyrażenie regularne)
l. wielozn.	—	—

- Aplikacja atrybutu do danego obiektu (\rightsquigarrow **wartość**)

```
[pos = subst].msd.all.size
```


Relacje, operacje (podstawowe)

- Równość

==

ten sam obiekt

=

takie same obiekty

!=

nierówność

/=

bez niejawnych konwersji

(obiekt \rightsquigarrow lista 1-elem.; lista węzłów \rightsquigarrow boolean)

niekoniecznie wygodne
w konkretnej sytuacji \rightsquigarrow **lukier**

Relacje, operacje (podstawowe)

• Równość

==

ten sam obiekt

=

takie same obiekty

!=

nierówność

/=

bez niejawnych konwersji

(obiekt \rightsquigarrow lista 1-elem.; lista węzłów \rightsquigarrow boolean)

niekoniecznie wygodne
w konkretnej sytuacji \rightsquigarrow **lukier**

• Typy proste

< <=

porównywanie liczb (brak arytmetyki!)

&& || ! =>

operacje logiczne

@

konkatenacja napisów

Relacje, operacje (na listach)

- Listy (działające też jako **zbiory**)

<code>[n]</code>	n -ty element
<code>[-n]</code>	n -ty od końca
<code>@</code>	konkatenacja
<code>.uniq</code>	\rightsquigarrow zbiór
<code>.size</code>	rozmiar

<code>contains</code>	zawieranie elementu
<code><=</code> <code>_<=_</code>	podciąg (?), podzbiór
<code>_ _</code> <code>_&_</code> <code>__</code>	operacje na zbiorach

Relacje, operacje (na listach)

- Listy (działające też jako **zbiory**)

<code>[n]</code>	n -ty element	<code>contains</code>	zawieranie elementu
<code>[-n]</code>	n -ty od końca	<code><=</code> <code>_<=_</code>	podciąg (?), podzbiór
<code>@</code>	konkatenacja	<code>_ _</code> <code>_&_</code> <code>__</code>	operacje na zbiorach
<code>.uniq</code>	\rightsquigarrow zbiór		
<code>.size</code>	rozmiar		

- Listy wieloznaczności

<code>.all</code>	lista wszystkich wartości	<code>~</code> <code>~~</code>	po staremu
<code>.sel</code>	lista wybranych wartości	<code>=</code> <code>==</code>	
<code>.val</code>	jedyna wybrana wartość, albo null		

Relacje, operacje (na listach)

- Listy (działające też jako **zbiory**)

<code>[n]</code>	<i>n</i> -ty element		<code>contains</code>	zawieranie elementu
<code>[-n]</code>	<i>n</i> -ty od końca		<code><=</code> <code>_<=_</code>	podciąg (?), podzbiór
<code>@</code>	konkatenacja		<code>_ _</code> <code>_&_</code> <code>__</code>	operacje na zbiorach
<code>.uniq</code>	↔ zbiór			
<code>.size</code>	rozmiar			

- Listy wieloznaczności

<code>.all</code>	lista wszystkich wartości		<code>~</code> <code>~~</code>	po staremu
<code>.sel</code>	lista wybranych wartości		<code>=</code> <code>==</code>	
<code>.val</code>	jedyna wybrana wartość, albo null			

przykład:

<code>[msd.sel = { [case=gen] * }]</code>		↔ <code>[msd==[case=gen]]</code>
↔ <code>[msd.case==gen]</code> ↔ <code>[case==gen]</code>		

nowość:

<code>[msd.sel = { [case=gen && numb=sg] * }]</code>		↔ <code>[{case,numb}=={gen,sg}]</code>

Relacje (międzywęzłowe, część I)

- Dominacja

>	krawędź pierwotna
->	krawędź wtórna
> [cond]	krawędź spełnia <i>cond</i>
> *	ciąg krawędzi
> {3, 5}	od 3 do 5 krawędzi
> * { : spec : }	węzły po drodze pasują do <i>spec</i>
> [-1]	krawędź do prawego syna

Relacje (międzywęzłowe, część I)

- Dominacja

>	krawędź pierwotna
->	krawędź wtórna
> [<i>cond</i>]	krawędź spełnia <i>cond</i>
> *	ciąg krawędzi
> {3,5}	od 3 do 5 krawędzi
> * {: <i>spec</i> :}	węzły po drodze pasują do <i>spec</i>
> [-1]	krawędź do prawego syna
<i>X</i> : <i>cond</i>	<i>X</i> taki, że <i>cond</i>

```
[type=node:s] > {,8} { : $X : $X !>* [orth=nie] : } [pos=fin]
```

```
[type=node:s] > {,8} { : $X && $X !>* [orth=nie] : } [pos=fin]
```

ŻLE →

Relacje (międzywęzłowe, część II)

- Precedencja
 - wg porządku krawędziowego (na **dzieciach danego węzła**)

<code>.sons</code>	lista dzieci węzła
<code>{ regex }</code>	specyfikacja zawartości listy

<code>[type=NG].sons</code>	=	<code>{ []* [pos=adj] [pos=subst] []* }</code>
<code>↔ [type=NG].sons</code>	>=	<code>{ [pos=adj], [pos=subst] }</code>

Relacje (międzywęzłowe, część II)

- Precedencja

- wg porządku krawędziowego (na **dzieciach danego węzła**)

<code>.sons</code>	lista dzieci węzła
<code>{ regex }</code>	specyfikacja zawartości listy

<code>[type=NG].sons</code>	=	<code>{ []* [pos=adj] [pos=subst] []* }</code>
<code>↔ [type=NG].sons</code>	>=	<code>{ [pos=adj], [pos=subst] }</code>

- wg porządku segmentowego

<code>.span</code>	lista segmentów pod węzłem
<code>regex</code> (bez kontekstu)	specyfikacja ciągu segmentów

<code>[type=NG]</code>	>	<code>([pos=adj] [pos=subst])</code>
------------------------	---	----------------------------------------

Relacje (międzywęzłowe, część II)

- Precedencja
 - wg porządku krawędziowego (na **dzieciach danego węzła**)

<code>.sons</code>	lista dzieci węzła
<code>{ regex }</code>	specyfikacja zawartości listy

<code>[type=NG].sons</code>	=	<code>{ []* [pos=adj] [pos=subst] []* }</code>
↪ <code>[type=NG].sons</code>	>=	<code>{ [pos=adj], [pos=subst] }</code>

- wg porządku segmentowego

<code>.span</code>	lista segmentów pod węzłem
<code>regex</code> (bez kontekstu)	specyfikacja ciągu segmentów

<code>[type=NG]</code>	>	<code>([pos=adj] [pos=subst])</code>
------------------------	---	----------------------------------------

Podsumowanie: **trzy warianty** wyrażen regularnych

`{| tak+ |}`

`tak+`

`"tak+"`

Zmienne

A priori — dowolnego typu (w tym lista)

<code>\$X</code>	bieżąca wartość
<code>\$X:=wyr</code>	przypisz wyrażenie do <code>\$X</code>
<code>\$X+=wyr</code>	dopisz wyrażenie do <code>\$X</code>

Przykłady:

nieciągłość (\wedge)

```
$A []* $B []* $C && $X > $A && $X !> $B && $X > $C
```

dopełniacz negacji

```
$X:=nie? [] [case=$C] && !$X.empty => $C=gen && ... ])
```

częste „y” w NG

```
[type=NG].span = { | ($Y+=y | [])* | } && $Y.size >= 2
```

Kwantyfikatory (pierwszego rzędu)

- Składnia

#X: *wyr* istnieje \$X takie, że *wyr*

##X: *wyr* dla każdego \$X zachodzi *wyr*

#3X: *wyr* istnieją **dokładnie 3** wartości \$X t. że *wyr*

#3,10X: *wyr* istnieje **pomiędzy 3 a 10** wartości \$X t. że *wyr*

- Przykład — najniższy wspólny przodek:

```
$X >* {$Y, $Z} && ##W: ($W >* {$Y, $Z} => $W >* $X)
```

Kwantyfikatory (pierwszego rzędu)

- Składnia

#X: *wyr* istnieje \$X takie, że *wyr*

##X: *wyr* dla każdego \$X zachodzi *wyr*

#3X: *wyr* istnieją **dokładnie 3** wartości \$X t. że *wyr*

#3,10X: *wyr* istnieje **między 3 a 10** wartości \$X t. że *wyr*

- Przykład — najniższy wspólny przodek:

```
$X >* {$Y, $Z} && ##W: ($W >* {$Y, $Z} => $W >* $X)
```

- Zasięg:

- domyślnie — **chunk** (np. zdanie)
- zmieniany przez **within**

Przykład: #5,X: \$X.base=abażur **within** [type=p]

Różności semantyczne

- specyfikacja / niezainicjowana zmienna \rightsquigarrow kwantyfikator \exists
w szczególności, obowiązuje zasięg kwantyfikatorów

przykład: `$X -> [type=coref] [] within [type=p] && ...`

Różności semantyczne

- specyfikacja / niezainicjowana zmienna \rightsquigarrow kwantyfikator \exists
w szczególności, obowiązuje zasięg kwantyfikatorów

przykład: `$X -> [type=coref] [] within [type=p] && ...`

- dopasowanie = wartościowanie, dla którego wychodzi `true`

Różności semantyczne

- specyfikacja / niezainicjowana zmienna \rightsquigarrow kwantyfikator \exists
w szczególności, obowiązuje zasięg kwantyfikatorów

przykład: `$X -> [type=coref] [] within [type=p] && ...`

- dopasowanie = wartościowanie, dla którego wychodzi `true`
a co z modyfikacjami zmiennych? `dublujemy`

przykład: `$X:=la* && !$X.empty && $X:="a*" && $X.pos=qub`

ale modyfikacje `to nie lukier`: `($Z+= [orth!=y] | y)+`

Różności semantyczne

- specyfikacja / niezainicjowana zmienna \rightsquigarrow kwantyfikator \exists
w szczególności, obowiązują zasięg kwantyfikatorów

przykład: `$X -> [type=coref] [] within [type=p] && ...`

- dopasowanie = wartościowanie, dla którego wychodzi `true`
a co z modyfikacjami zmiennych? `dublujemy`

przykład: `$X:=la* && !$X.empty && $X:="a*" && $X.pos=qub`

ale modyfikacje `to nie lukier`: `($Z+= [orth!=y] | y)+`

- negacja

niby proste, ale np. co ma znaczyć `!=` ?

`string != string-spec`

`string` nie spełnia `string-spec`

`struct != struct-spec`

`struct` nie równa się pewnemu `struct-spec`

`string-spec1 != string-spec2`

bez sensu

`struct-spec1 != struct-spec2`

istnieją i są różne

Flagi

Składnia: *wyr/flaga*

- dotyczące stringów

/I */i*

uwzględnij/ignoruj wielkość liter

/a(loc)

użyj ustawień lokale *loc*

/X */x* */xl* */xr*

toleruj podcięcia (z żadnej/lewej/prawej/obu stron)

- dotyczące zmiennych

/E */e*

zmienne mają różne/dowolne wartości

(Tiger: */e*, PML-TQ: */E*)

- dotyczące segmentacji

/S */s*

zabroń/dozwoł rozsegmentowanie zap. prostych

(bez rozspacjowania: np. *byłby* \rightsquigarrow *byłby*)

/H */h*

zabroń/dozwoł przeniesienie słowa do nowej linii

Post-processing

- łańcuchy zapytań

```
zap1 ;; zap2
```

wykonaj *zap1*, a na **każdym** jego wyniku *zap2*
(*zap2* może korzystać ze zmiennych z *zap1*)

Przykłady:

przykrój wynik

```
[type=VG] > $X:=[type=NG]3 ;; $X[2]
```

AG NG AG na raty

```
$X:=[type=NG] $Y:=[type=AG] ;; [type=AG] $X && $Y
```

Post-processing

- łańcuchy zapytań

```
zap1 ;; zap2
```

wykonaj *zap1*, a na **każdym** jego wyniku *zap2*
(*zap2* może korzystać ze zmiennych z *zap1*)

Przykłady:

przykrój wynik

```
[type=VG] > $X:=[type=NG]3 ;; $X[2]
```

AG NG AG na raty

```
$X:=[type=NG] $Y:=[type=AG] ;; [type=AG] $X && $Y
```

- funkcje statystyczne (do konsultacji)

```
zap ;; niby-sql
```

wykonaj *zap* i na **wszystkich** jego wynikach *niby-sql*

- siła wyrazu prostego SQL, ale składnia raczej inna (graficznie?)
- wyr. logiczne SQL \rightsquigarrow zapytania

Wstępny przykład:

z czym często jem?

```
jem [case=$C] ;; $C grpby $C ordby count() desc
```

Dziękujemy!