

Základy využití korpusu v praxi **cjb75**

Středa: 10.00-11.30 G13

3. 4. 2019

Korpus jako zdroj dat pro výzkum slovotvorby

<http://www.ujc.cas.cz/elektronicke-slovniky-a-zdroje/Slovnik-afixu-html>

<http://ufal.mff.cuni.cz/derinet>

<https://nlp.fi.muni.cz/projects/derivancze/>

Jak zadat dotaz pro hledání slov, která mají společné slovotvorné vlastnosti

(lingvistické termíny: morfém, afix, kořen, kmen, slovní druh, substantivum, adjektivum, sloveso, ..., gramatická kategorie, rod, číslo, pád, osoba ...; termíny pro formální zadání: řetězec, token, lemma, morfologická značka/tag, pozice/atribut, hodnota, technické řešení, ...)

Adjektiva od sloves typu *koupací*

Slovní formulace – tvrzení, která musí platit, podmínka nutná/dostačující, využití regulárních výrazů a logických operací, využití filtrů, pozorování dat a úprava dotazu.

Chceme vyhledat všechna adjektiva taková, že lemma končí na *ci*.

Hledat v korpusu

Korpus: **syn2015**

Typ dotazu: **Lemma** ?

Dotaz: ***ci**

Předchozí dotazy lze zobrazit také pomocí šipky dolů (další tip)

Slovní druh: **Nespecifikováno**

► Specifikovat kontext

► Omezit hledání

Hledat

Výskytů: 480 720 i.p.m. 0 3 981,16 (1 vztázeno k celému "syn2015") ARF 0 257 539,28 Výsledek je promíchaný		1 / 12 018 ►►
Výběr řádků:	základní	Atributy:
1	příští sezóně v Pardubicích . Devětadvacetiletý bek se s vedením odpady určitá rizika . Při elektronických aukcích dochází v průběhu Mussik píše , Spousta aut, kočáru, rychle Bank ke včerejšímu dni celkem 54 tisíc klientů . O něj vede schodiště z 19. století Koloděj a její se opakován upozornění na osobní odpovědnost za jejich obsah ; zabil ji šok . Nechal ji ležet, stále s kapitalismu v Rakousku , ale přesto zůstal vášnivým idealistou , obývák zaplaví zlaté světlo . Mrkám , abych dostatečně zvláčnila a bouricí práce * Blok ii . Práce vnitřní a vzdělávání je zapotřebí v případě , že jsou splňeny dvě energie : energie elektromagnetických vln a tepelné energie . Při dalším roce hodně dojde . Zbytky ze štědrovečerního stolu putovaly kdy v Terrym opět zahledí muže , který sedával u touží evropští muži ? Společnost , která jako první představí	úřadujícího zadávacího jezdících zbývajících cestujících rozmnožovací horším věřícím páličí dokončovací následující připínacích domácím hracího fungující
2		extraligového mistra dohodl na nové smlouvě . BĚLC řízení (při sledování na portálu) k poklesu cen elektrických vozů využídlá bez rozmyslu do hemžícic 36 tisíc zákazníků tedy může UniCredit dále usilovat Cesta vzhůru Salón na horní palubě Nemůžete zabolít přístroj nepřicházel v úvahu . Tyto obecné směrnice oděvem , obklopenou pachem seškařeného masa . v pokrok , který spatoval především v emanciaci a oči . Zornice se stáhnou , přesně , jak se * Blok iii . Vady na tepelněizolační obálce budovy ka podminky (Buckley - Caple , 2004 , s. 32 prechodných dějích vždy dochází k využívání elekt zvířatům , podarovaný byly i stromy v zahradách , ab stolu v Keithově bytě a po každém kole hbitě a přípravek proti vypadávání vlasů , udělá neskutečný

výsledek je značně přegenerovaný.

Lze dotaz optimalizovat?

Všimněte si:

Filter	lemma	Freq	
1	p / n	domácí	24910
2	p / n	pomocí	15350
3	p / n	následující	13689
4	p / n	vedoucí	11597
5	p / n	budoucí	8049
6	p / n	vynikající	5245
7	p / n	stávající	5179
8	p / n	rostoucí	4725
9	p / n	cestující	4608
10	p / n	odpovídající	4321
11	p / n	vzdělávací	4171
12	p / n	rozhodující	4010
13	p / n	žádoucí	3592
14	p / n	týkající	3445
15	p / n	žijící	3424
16	p / n	související	2993
17	p / n	obývací	2969
18	p / n	věřící	2719
19	p / n	stojící	2600
20	p / n	ležící	2543
21	p / n	zbývající	2530
22	p / n	psací	2478
23	p / n	existující	2475
24	p / n	pracující	2248

obyvat – *obyvací* i *obyvající*

zbyvat – *zbyvající*

Existují dva významy

a) vlastnost vyjadřuje, že něco je určeno k tomu, co označuje základové sloveso: *obyvací kuchyň* je nejen k vaření a jedení, ale i k tomu, abychom v ní *pobývali/přebývali*;

b) transpozice významu děje (vlastnost toho, který dělá to, co označuje základové sloveso): zvíře *obyvající oblast/světadíl/ ...* = jde pouze o nominalizaci verba (převod/transpozici z kategorie slovního druhu).

Rozlišujeme dvě slovotvorné třídy:

-a-cí od kmene minulého/infinitivního (**tzv. adjektiva účelová**)

-aj-i-cí od kmene přítomného (**tzv. adjektiva procesuální**)

Jak formulovat dotaz?

Pokusíme se odstranit ta adjektiva, u nichž před sufixem *-cí* předchází kmenotvorný sufix prémenného kmene. Opěrným tvarem je tvar 3. osoby sg. indikativu prémantu aktiva, tedy buď *-ou-*, nebo *-i-* (před *-i-* může ještě předcházet *-j-/uj-/-[eě]j-/aj-*).

Co může předcházet před *-cí* při derivaci od kmene minulého? Mohou nastat případy, kdy je kmen minulý a přítomný homonymní, takže při homonymii sufixu budeme mít možnou homonymii adjektivních derivátů?

Existují v češtině slovesa, jejichž kmen minulý (opěrný tvar je l-ové příčestí) končí na *oul/il*?

Dokážete si vzpomenout?

Podívejte se do korpusu.

Dotaz je formulován slovně tak, že **chceme vyhledat všechny tvary slovesa l-ovéhopříčestí maskulina singuláru takové, že končí na oul nebo na il**. V jazyce cql vypadá dotaz takto:

[lc=".*(oul|il)" & tag="Vp[MI]S.*"]

Výsledek je prázdný konkordanční seznam.

Můžeme tudíž použít negativní filtr a odstranit lemmata na *.*(ou|í)cí*.

Sledujeme-li frekvenčně utříděný seznam, zjistíme, že se v něm vyskytují i adjektiva, která sice na *cí* končí, ale nejsou tvořena od sloves, a tak nespadají ani do kategorie účelových, ani do kategorie procesuálních adjektiv.

První je adjektivum *domácí* se vztahem k adverbiu *doma*.

Zakončení je *áci*.

Můžeme si položit otázku, zda existují v češtině adjektiva od sloves, která končí na *áci*?

Můžeme si na ně a) zkoušet vzpomenout, b) vyhledat pomocí pozitivního filtrování všechna adjektiva na *.*áci* a prohlédnout si je, c) zkontovalovat, zda existují slovesné tvary l-ového

příčestí v singuláru maskulina na .*ál a pokud ano, tak jak se od takových tvarů tvoří adjektiva s významem účelu.

Odpověď na a): ?;

b) nalezneme pouze lemma *domácí* a komposita se druhým členem *domácí*;

c) [`[lc=".*ál" & tag="Vp[MI]S.*"]`] vyhledáme 126 lemmat, přičemž vidíme, že á se při tvoření účelového adjektiva buď krátí (*hrát* → *hrací*, *přát* → *přací*, *sát* → *sací*,), nebo se střídá s oj (*stát* → *stojací*);

Dále vidíme adjektiva jako *zvířecí* a *kuřecí*, jde o jinou slovotvornou třídu (adjektiv tvořených ze substantiv označující vztah přivlastnění/podobnosti základovému substantivu), ale jde také o jiný slovotvorný typ, a sice o skupinu adjektiv tvořených příponou *-í*/ konverzí ke vzoru *jarní*, přičemž základem je o skupiny substantiv skloňovaných podle vzoru *kuře* kmen rozšířený o kmenotvorné *-[eě]t-*, které alternuje s *-[eě]c-*. V případě, že se základové substantivum neskloňuje podle vzoru *kuře*, pak se příslušné adjektivum tvoří pouze příponou *-í*/konverzí ke vzoru *jarní* (*psí*, *vlčí*, *mroží*, *kozí*, *myší*, ...).

Podívejme se, zda tato adjektiva mohou mít homonymní zakončení s adjektivy tvořenými ze sloves.

Vyhledáme pomocí pozitivního filtru adjektiva, která končí na *[ěe]ci*.

Vidíme, že stejně zakončení mají I adjektiva jako *obráběcí*, *prováděcí*, *předváděcí*, *secí*, *sklizečí*, *dobíjecí*, *secí*, ...

Aplikovat operaci "filtr"

Filtr: negativní

Rozsah hledání: od: 0 do: 0, včetně KWIC

Typ dotazu: Lemma

Dotaz: .*ouříčí

Slovní druh: Nespecifikováno

Hledat

Kapitolem u Dokončku, ale přesto zůstal výsledek výsledkem. už výsledek u pokrač. který má

Celkem: 2 772 položek (56 stránek)

	Filter	lemma	Freq	
1	p / n	domácí	24910	<div style="width: 100%;">██████████</div>
2	p / n	pomocí	15350	<div style="width: 75%;">███████████</div>
3	p / n	vzdělávací	4171	<div style="width: 15%;">████</div>
4	p / n	obývací	2969	<div style="width: 10%;">███</div>
5	p / n	psací	2478	<div style="width: 10%;">███</div>
6	p / n	řídící	2055	<div style="width: 10%;">███</div>
7	p / n	zvířecí	1631	<div style="width: 5%;">██</div>
8	p / n	parkovací	1481	<div style="width: 5%;">██</div>
9	p / n	dýchací	1417	<div style="width: 5%;">██</div>
10	p / n	hrací	1291	<div style="width: 5%;">██</div>
11	p / n	ovládací	1226	<div style="width: 5%;">██</div>
12	p / n	kuřecí	1187	<div style="width: 5%;">██</div>
13	p / n	přijímací	1129	<div style="width: 5%;">██</div>
14	p / n	testovací	926	<div style="width: 5%;">██</div>
15	p / n	poznávací	883	<div style="width: 5%;">██</div>
16	p / n	krycí	847	<div style="width: 5%;">██</div>
17	p / n	napájecí	843	<div style="width: 5%;">██</div>
18	p / n	měřicí	826	<div style="width: 5%;">██</div>
19	p / n	vyšetřovací	811	<div style="width: 5%;">██</div>
20	p / n	chladicí	797	<div style="width: 5%;">██</div>

Jak odstranit přegenerované doklady typu *domácí*, *zvířecí*, *kuřecí*, ...?

Ruční analýza dat.

Další nástroje pro hledání slovotvorných zákonitostí.

Vyhledávání dvojic slov podle zadání společné a odlišné časti pomocí nástroje Morfio.

Morfio

← společný → odlišný → +> Morf. specifikace:

vzor 1: přídavná jména

vzor 2: slovesa

Další vzor

Korpus: Frekvence vyšší než: Hledají se: Vyhodnocují se:

Velikost písmen: ignorovat

Odkaz na toto zadání: <http://morph.korpus.cz/nfXUOR2U>

Souhrn	Výpis	Produktivita	vzor 1	vzor
	vzor 1 ▲▼ (fq ▲▼)		vzor 2 ▲▼ (fq ▲▼)	
1	adresovací (10)		adresovat (350)	
2	aportovací (15)		aportovat (40)	
3	aranžovací (22)		aranžovat (113)	
4	aretovací (2)		aretovat (14)	
5	armovací (54)		armovat (9)	
6	asfaltovací (2)		asfaltovat (7)	
7	auditovací (4)		auditovat (21)	
8	bagrovací (2)		bagrovat (12)	
9	balíčkovací (1)		balíčkovat (4)	
10	balicí (183)		balit (1200)	
11	balzamovací (9)		balzamovat (13)	
12	barvicí (42)		barvit (478)	
13	batolecí (84)		batolit (61)	
14	bdící (62)		bdít (579)	
15	bedníci (52)		bednit (5)	
16	běhací (32)		běhat (3248)	
17	bělicí (59)		bělet bělit bílit (58)	
18	betonovací (2)		betonovat (70)	
19	biflovací (2)		biflovat (31)	
20	biřmovací (6)		biřmovat (13)	
21	bivakovací (3)		bivakovat (29)	
22	blednoucí (61)		blednout (406)	
23	blikací (3)		blikat (484)	
24	blinkací (1)		blinkat (21)	
25	blogovací (23)		blogovat (49)	
26	blokovací (39)		blokovat (959)	
27	blyštící (40)		blyštět (113)	
28	bobtnací (2)		bobtnat (137)	
29	bodací (1)		bodat (379)	

Jak vypadají výsledky korpusových analýz v lexikografickém díle zaměřeném na popis slovotvorných prostředků:

<http://www.slovnikafixu.cz/heslar/-c%C3%AD>

10. 4. Dú: Jak lze v korpusu vyhledat substantiva tvořená příponou *-č*, která označují osoby vykonávající činnost označenou základovým slovesem: *řidič*, *nosič*, *sběrač*, *očišťovač*, *hráč*, ...

Pokuste se:

- formulovat dotaz (v přirozeném jazyce a v jazyce cql);
- pozorovat korpusová data vyhledaná na základě dotazu a dotaz specifikovat;
- popsat, jaká pozorování lze využít při reformulaci dotazu/používání filtrů;
- popsat možnosti využití nástroje Morfio k vyhledání dvojic sloveso/substantivum označující člověka, který dělá to, co označuje základové sloveso typ *nosit/nosič*;
- podívejte se na heslo *-č* ve Slovníku afixů užívaných v češtině a porovnejte svá pozorování s tím, co se uvádí v hesle. Narazili jste v korpusových datech na něco, co by bylo v rozporu s tím, co se uvádí v textu hesla?
- Jak byste vysvětlili slova jako *držič*, *sedič*, *tiskač*, *snoubič*, *strojíč*?