

Základy využití korpusu v praxi **cjb75**

pondělí: 8.00-9.30 G13

12. 4. 2021

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:

Klávesnice

.*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 (11 vztázeno k celému "syn2015") ARF 0 257 539,28 Výsledek je promichán		1 / 12 018 ►►
Výběr řádků:	základní	Atributy:
<input type="checkbox"/> ▲	příští sezóně v Pardubicích . Devětadvacetiletý bek se s vedením	úřadujícího extraligového mistra dohodl na nové smlouvě . BĚLC
<input type="checkbox"/> ▲	odpady určitá rizika . Při elektronických aukcích dochází v průběhu	zadávacího řízení (při sledování na portálu) k poklesu cen
<input type="checkbox"/> ▲	Mussik příše „ Spousta aut, kočáru, rychle	jezdící elektrických vozů výjdežela bez rozmyslu do hemžicic
<input type="checkbox"/> ▲	Bank ke včerejsímu dni celkem 54 tisíc klientů . O	zbývajících 36 tisíc zákazníků tedy může UniCredit dále usilovat
<input type="checkbox"/> ▲	něj vede schodiště z 19 . století Koloděj a její	cestující Cesta vzhůru Salón na horní palubě Nemůžete zabol
<input type="checkbox"/> ▲	se opakován upozornění na osobní odpovědnost za jejich obsah ;	rozmnožovací přístroj nepřichází v úvahu . Tyto obecné směrnice
<input type="checkbox"/> ▲	zabil ji šok . Nechal ji ležet, stále s	horším oděvem , obklopenou pachem seškařeného masa .
<input type="checkbox"/> ▲	kapitalismu v Rakousku , ale přesto zůstal vášnivým idealistou ,	vějířem v pokrok , který spatoval především v emancipaci a
<input type="checkbox"/> ▲	obyvák zaplaví zlaté světlo . Mrkám , abych dostatečně zvlhčila	pálící oči . Zornice se stáhnou , přesně , jak se
<input type="checkbox"/> ▲	a bourcej práce * Blok ii . Práce vnitřní a	dokončovací * Blok iii . Vady na tepelněizolační obálce budovy ka
<input type="checkbox"/> ▲	vzdělávání je zapotřebí v případě , že jsou splněny dvě	následující podmínky (Buckley - Caple , 2004 , s. 32
<input type="checkbox"/> ▲	energie : energie elektromagnetických vln a tepelné energie . Při	prepiñacích prechodných dějích vždy dochází k vyuzařování elekt
<input type="checkbox"/> ▲	dalším roce hodně dojily . Zbytky ze štědrovečerního stolu putovaly	domácím zvíratům , podarovaný byly i stromy v zahradách , ab
<input type="checkbox"/> ▲	kdy v Terrym opět zahledí muže , který sedával u	hracího stolu v Keithově bytě a po každém kole hbitě a
<input type="checkbox"/> ▲	touží evropští muži ? Společnost , která jako první představí	fungující 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 – obývací i obývající

zbyvat – zbyvající

Existují dva významy

a) vlastnost vyjadřuje, že něco je určeno k tomu, co označuje základové sloveso: *obývací 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 *obývající 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 pl. indikativu prémantu aktiva, tedy bud *-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-ového příčestí 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 *ácí*.

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

Můžeme si na ně a) zkusit vzpomenout, b) vyhledat pomocí pozitivního filtru 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 bud' krátí (*hrát* → *hrací*, *přát* → *přací*, *sát* → *sací*), nebo se střídá s *oj* (*stát* → *stojací*);

Dále vidíme adjektiva jako ***zvřecí*** 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 -i/ konverzí ke vzoru *jarní***, přičemž základem je substantivum skloňované podle vzoru ***kuře***, jehož kořen je 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 -i/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 stejné 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

Konfiguraci v Pøekoučku mìlo pøejst zájemcùm ideálníto... [výjimek](#) [v pokraçení](#)

Celkem: 2 772 položek (56 stránek)

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

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.

Jazyk: čeština

<+ ~~společný~~ vzor 1: .+ | ~~odlišný~~ vzor 2: .+ > Morf. specifikace: vlastní tag > V.MS.*

vzor 1: .+ | ~~odlišný~~ vzor 2: .+ > Morf. specifikace: vlastní tag > V.MS.*

Přidat vzor

Korpus: SYN2015 Frekvence vyšší než: 0 Hledat: tvary Vyhodnotit: tvary

A = a Alternace

Hledat Nové zadání Odkaz na toto zadání: <http://morfio.korpus.cz/Gz1Xv7eX> Nápověda

	vzor 1 ▲▼ (fq ▲▼)	vzor 2 ▲▼ (fq ▲▼)
1	vzdělával (15)	vzdělávací (1977)
2	řídil (742)	řídicí (1402)
3	psal (1779)	psací (890)
4	obýval (63)	obývací (849)
5	parkoval (24)	parkovačí (803)
6	ovládal (123)	ovládací (699)
7	přijímal (128)	přijímací (601)
8	testoval (56)	testovačí (584)
9	poznával (80)	poznávací (579)
10	dýchal (107)	dýchací (530)
11	vyšetřoval (69)	vyšetřovačí (528)
12	kryl (78)	krycí (520)
13	chladił (2)	chladicí (477)
14	měřil (135)	měřicí (471)
15	napájel (3)	napájecí (457)
16	leplil (23)	lepicí (439)
17	čerpal (96)	čerpací (434)
18	pořizoval (33)	pořizovací (417)
19	sedal (34)	sedací (408)
20	skládal (126)	skládací (408)

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

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

Podobně lze užít *Morfio* i k vyhledání dvojic opěrný tvar – procesuální adjektivum

Jazyk: čeština

<+ společný odlišný +> Morf. specifikace:

vzor 1: .+ vlastní tag > V..P...3.*

vzor 2: .+ přídavná jména A.*

Přidat vzor

Korpus: SYN2015 Frekvence vyšší než: 0 Hledat: tvary Vyhodnotit: tvary

A = a Alternace

Hledat Nové zadání Odkaz na toto zadání: <http://morph.korpus.cz/hQ4dKEwm> Nápověda

	vzor 1 ▾▼ (fq ▾▼)	vzor 2 ▾▼ (fq ▾▼)
1	následují (667)	následující (6795)
2	budou (48880)	budoucí (4812)
3	vedou (3673)	vedoucí (4631)
4	vynikají (337)	vynikající (3975)
5	rostou (2199)	rostoucí (3173)
6	odpovídají (1408)	odpovídající (3003)
7	rozhodují (801)	rozhodující (2956)
8	stávají (1938)	stávající (2889)
9	týkají (1204)	týkající (2507)
10	žijí (4944)	žijící (1767)
11	souvísejí (694)	souvísející (1700)
12	stojí (2750)	stojící (1628)
13	leží (1337)	ležící (1617)
14	obsahují (2738)	obsahující (1562)
15	zbývají (509)	zbývající (1543)
16	připomínají (1567)	připomínající (1542)
17	působí (2904)	působící (1372)
18	vycházejí (1667)	vycházející (1165)
19	umožňují (2730)	umožňující (1146)
20	chybějí (680)	chybějící (1130)

Výhody nástroje *Morfio*: vyšší přesnost (pracujeme v tomto případě s opěrnými tvary, a tudíž přesně definujeme derivační vztah základového a odvozeného slova)

Nevýhody nástroje *Morfio*: menší pokrytí (pracujeme v tomto případě s opěrnými tvary, a tudíž se jednak opíráme o výsledky automatické analýzy – desambiguace nemusí být přesná a také redukujeme data na ty opěrné tvary, které jsou doloženy v analyzovaném korpusu – např. v korpusu SYN2005 není desambiguován/ „sdružená hodnota“/ tvar *čutal* slovesa *čutat*, a tudíž není adjektivum *čutací* nástrojem *Morfio* přiřazeno do dvojice vyhledané uvedeným způsobem). A samozřejmě také nebudou nalezeny doklady typu přál/přací.

V nástroji lze sice použít alternace, ale i ty mohou působit přegenerování výsledků.

Nevýhod je ovšem v uvedeném případě méně, výhody převažují.

Korpus: syn2005 | Dotaz: **čutal** (1 výskyt) ► Promíchat: ✓

Výskytů: 1 | i.p.m.: 0,01 (vztaženo k celému korpusu) | ARF: 1 | Výsledek je promíchán

Výběr řádků: základní ▾

<input type="checkbox"/>	pasty Kolynos , a jak jsem šel ke schodům ,	čutal/čutat/VpYS--XR-AA---I	jsem do ní trepkou s beránkem , co jsem měl
--------------------------	---	-----------------------------	---

19. 4. 2021 Dú: Jak lze v korpusu vyhledat substantiva tvořená příponou $-n(i)/-t(i)$ paradigmaticky od všech sloves (*řízení, nošení, sbírání, hrání, krytí, pohnutí, ...*).

Pokuste se:

- a) formulovat dotaz (v přirozeném jazyce a v jazyce cql);
- b) pozorovat korpusová data vyhledaná na základě dotazu a dotaz specifikovat;
- c) popsat, jaká pozorování lze využít při reformulaci dotazu/používání filtrů;
- d) popsat možnosti využití nástroje Morfio k vyhledání dvojic sloveso/substantivum;
- e) podívejte se na heslo $-i$ ve Slovníku afixů užívaných v češtině.