

Základy využití korpusu v praxi **cjbb75**

Středa: 10.50-12.20 G13

18. 4. 2018

Jak lze v korpusech hledat doklady pro výzkum morfologie?

Mějme tvrzení:

Všechna česká maskulina v genitivu plurálu mají koncovku na *-ů*.

Máme 6 vzorů: *pán/pánů*, *hrad/hradů*, *muž/mužů*, *stroj/strojů*, *předseda/předsedů*, *soudce/soudců*.

Existují z tohoto pravidla nějaké výjimky?

Vzpomenete si na ně?

Jak jsou obvyklé (jsou to slova z centra/periferie slovní zásoby)?

Jak vyhledat data v korpusu:

Hledat v korpusu

Korpus:

Typ dotazu:

Vložit tag | Vložit 'within' | Klávesnice

Dotaz:

Předchozí dotazy lze zobrazit také pomocí šipky dolů [\(další tip\)](#)

Výchozí atribut: [\(popis morf. značek\)](#)

► Specifikovat kontext

► Omezit hledání

Frekvenční distribuce

Frekvenční limit:

Úroveň	Atribut	Nerozlišovat velikost	Pozice	(Node) začít od
1.	<input type="text" value="lc [lowercase word]"/>	<input type="checkbox"/>	<input type="text" value="Node"/>	<input type="text" value="slova KWIC nejvíce vlevo"/>

Frekvenční seznam

1

Minimální frekvence: 1

Použít

Celkem: 16 684 položek (334 stránek)

	Filter	lc [lowercase word]	Freq	
1	p / n	lidí	45314	
2	p / n	milionů	19697	
3	p / n	metrů	13055	
4	p / n	peněz	11968	
5	p / n	dní	11476	
6	p / n	měsíců	9780	
7	p / n	dolarů	9700	
8	p / n	mužů	8855	
9	p / n	kilometrů	8550	
10	p / n	důvodů	7973	
11	p / n	druhů	7828	
12	p / n	bodů	7279	
13	p / n	dnů	7181	
14	p / n	problémů	7062	
15	p / n	zdrojů	6837	
16	p / n	států	5616	
17	p / n	stromů	5576	
18	p / n	rodičů	5418	
19	p / n	projektů	5376	
20	p / n	členů	5321	

Aplikovat operaci "filtr"



Filtr:

negativní

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

Typ dotazu:

Slovní tvar



[Klávesnice](#) | [Předchozí dotazy](#)

Dotaz:

*0

Předchozí dotazy lze zobrazit také pomocí šipky dolů [\(další tip\)](#)

Slovní druh: Nespecifikováno Shoda velikosti písmen:

Hledat

Celkem: 1 157 položek (24 stránek)

	Filter	lc [lowercase word]	Freq	
1	p / n	lidí	45314	
2	p / n	peněz	11968	
3	p / n	dní	11476	
4	p / n	obyvatel	4154	
5	p / n	přátel	3405	
6	p / n	°	3210	
7	p / n	mm	3152	
8	p / n	windows	2279	
9	p / n	koní	2265	
10	p / n	§	2141	
11	p / n	dospělých	1234	
12	p / n	times	1082	
13	p / n	cestujících	1076	
14	p / n	nemocných	931	
15	p / n	známých	921	
16	p / n	příbuzných	907	
17	p / n	m2	859	
18	p / n	nepřátel	764	
19	p / n	bratří	694	
20	p / n	zlatých	576	
21	p / n	kněží	511	

Jak lze výjimky z výše uvedeného pravidla dále kategorizovat?

Jednoduše je lze rozdělit podle tří zastoupených koncovek u prvních 20:

- končící na -í (typ *lidí/dní*)
- bez koncovky/ s nulovou koncovkou (typ *peněz-0/přátel-0*)
- s adjektivní flexí (typ *dospělých/zlatých*)

Vidíme, že jsou zastoupeny oba rody, jak maskulina životná, tak neživotná.

Pozorujme jednotlivé typy z hlediska frekvence:

► Negativní filtr: .*ů (118 236 výskytů) ► Pozitivní filtr: .*í (60 797 výskytů)

Frekvenční seznam

1

Minimální frekvence:

[Použít](#)

Celkem: 21 položek (1 stránka)

	Filter	lc [lowercase word]	Freq	
1	p / n	lidí	45314	
2	p / n	dní	11476	
3	p / n	koní	2265	
4	p / n	bratří	694	
5	p / n	kněží	511	
6	p / n	hostí	433	
7	p / n	podlidí	26	
8	p / n	spolubratří	14	
9	p / n	nadlidí	10	
10	p / n	bří	10	
11	p / n	pralidí	9	
12	p / n	pakoní	7	
13	p / n	kachlí	6	
14	p / n	velekněží	5	
15	p / n	opolidí	3	
16	p / n	tatí	3	
17	p / n	reagencí	3	
18	p / n	novokněží	2	
19	p / n	člověkodní	2	
20	p / n	afghání	2	
21	p / n	pololidí	2	

Chyby:

poradil . Rozbrečel jsem se a začal ječet : „ **TATÍ** , JÁ MUSIM ČURAT ! “ Což bylo dost ponižující

. Podruhé dětský hlásek , který se ptal : “ **Tatí** , co ten pán dělá ? “ V obou případech

Zaskočí nás , když syn ve školce prohlásí : „ **Tatí** , chtěl bych být holčička . “ Prohrábeme si stříště

necháme reagovat s jednou ze štěpících látek . První sada **reagencií** chemicky modifikuje ty nukleotidy , pro něž jsou specifické ,
mikrozkumavce jednoduše tak , že se DNA smíchá se souborem **reagencií** a mikrozkumavka se vloží do termálního cykléru (termocyklér)
dobře táhnoucí digestoři nebo na volném prostranství . I zbytky **reagencií** k jeho výrobě likvidujeme v digestoři . Navážíme dvojnásobek teoreticky

Odstraníme tvary na *-í* a lemmata na *.*[ýí]*

1

Minimální frekvence:

Celkem: 857 položek (18 stránek)

	Filter	lc [lowercase word]	Freq ▼	
1	p / n	peněz	11968	
2	p / n	obyvatel	4154	
3	p / n	přátel	3405	
4	p / n	°	3210	
5	p / n	mm	3152	
6	p / n	windows	2279	
7	p / n	§	2141	
8	p / n	times	1082	
9	p / n	m2	859	
10	p / n	nepřátel	764	
11	p / n	reuters	508	
12	p / n	klatov	450	
13	p / n	poděbrad	384	
14	p / n	km2	346	
15	p / n	m3	308	
16	p / n	cm3	302	
17	p / n	karpát	284	
18	p / n	beatles	278	
19	p / n	drobných	251	
20	p / n	jo	233	

Frekvenční seznam

1 ▶

Minimální frekvence:

Celkem: 279 položek (6 stránek)

	Filter	lc [lowercase word]	Freq	
1	p / n	dospělých	1234	
2	p / n	cestujících	1076	
3	p / n	nemocných	931	
4	p / n	známých	921	
5	p / n	příbuzných	907	
6	p / n	zlatých	576	
7	p / n	pracujících	484	
8	p / n	rozhodčích	451	
9	p / n	nezaměstnaných	333	
10	p / n	radních	271	
11	p / n	nadřízených	190	
12	p / n	podřízených	179	
13	p / n	poddaných	160	
14	p / n	obžalovaných	147	
15	p / n	kinských	143	
16	p / n	neznámých	137	
17	p / n	starých	134	
18	p / n	mluvčích	117	
19	p / n	bližních	113	
20	p / n	zlotých	111	

Co můžeme na základě pozorovaných dat říci o slovech s výjimečnou koncovkou u maskulin v gen. pl.?

1. Do skupiny s koncovkou *-í* patří omezený seznam slov, mezi nimi jsou ovšem buď domácí slova velmi frekventovaná, nebo jejich deriváty. Nefrekventovanou výjimkou je nesklonný název měny/vlastní jméno *a/Afghání* (adaptace).
2. Do skupiny bez koncovky patří z domácí slovní zásoby pouze substantiva *peníze*, *sudety* a životná (*ne*)*přítel*, *obyvatel* a propria – plurálie tantum (*Klatovy*, *Poděbrady*, *Karpaty*). Dále se objevují nesklonná přejatá/adaptovaná substantiva, zkratky, atd.

3. Adjektivní flexi mají substantiva s adjektivní flexí (*radní, mluvčí, zlatý*) a substantivizovaná adjektiva.

ÚKOL na 25. 4. 2018

Porovnáme-li maskulina v pozorovaném tvaru s femininy a neutry, zjistíme, že dvě výjimečné koncovky (-í a -0) figurují v genitivu plurálu právě u vzorů feminin a neuter:

růže/růží, píseň/písni, kost/kostí, moře/moří, stavení/stavení a žena/žen, město/měst, kuře/kuřat.

Platí i zde nějaké výjimky?

Vzpomenete si na ně?

Použijte k jejich zjištění korpus.

Jakého rodu jsou *Tatry, Krkonoše, Beskydy*?

Všimněte si, jak výjimečné koncovky u maskulin plurálií tantum působí na nejistotu při určení rodu u rodilých mluvčích.