

Lexikální databáze DeriNet jako formální model tvoření slov v češtině

Magda Ševčíková a Zdeněk Žabokrtský

📅 23. 11. 2021



Charles University
Faculty of Mathematics and Physics
Institute of Formal and Applied Linguistics



unless otherwise stated


O DeriNetu


O morfémech

O paradigmatech

Závěrečné poznámky

0 DeriNetu





DeriNet jako formální model slovotvorby

- v pojmech teorie grafů:
 - lemma = uzel
 - derivace = hrana
 - slovotvorné hnízdo = strom
 - všechny derivační vztahy v jazyce = les

Odkud se v DeriNetu berou uzly?

- v prvních verzích DeriNetu (r. 2013): cca 200k korpusově nejčastějších lemmat
- od r. 2015: 1M lemmat z MorfFlex.CZ (Hajič & Hlaváčová 2013)
- množinu lemmat vždy synchronizujeme s novými verzemi MorfFlexu
- příklady nedávných změn: jiné pojetí homonym, přidaná vlastní jména, změny v technických příponách lemmat atd.

Odkud se v DeriNetu berou hrany?

- hlavní metodologický přístup: oportunní predace
 - kombinace nejrozličnějších datových zdrojů, pravidlových metod, strojového učení, vlastních anotací apod.
 - desítky komponent
- technické řešení: po aktualizaci množiny lemmat lze spustit všechny komponenty pro generování hran "od nuly"
- aktuálně cca 840k hran

Ještě k velikosti


- obvyklé reakce z publika na 1M lemmat a 840k derivací:
 - nemluvčí češtiny: *Wow!*
 - mluvčí češtiny: *Bože, co to tam máte za divná slova?!?*
- relativní četnost 1 ku 2^{20} : *detailizování, pětasedmdesátinásobek, rojený, sprostácky, anekdotářský, uzounce, zpatlání, igelitově, rozfrázovat, štokovací*
- rychlé jasné snadné řešení: minimální práh na počet korpusových výskytů
- problém specifický pro modelování slovtvorby: vynechání periferie vede k rozpojení i v centrálnější části slovní zásoby

Korpusové frekvence v DeriNetu

- nutnosti hranice mezi centrem a periferií se úplně vyhnout neumíme
- ale můžeme tu hranici vytlačit co nejvíce do periferie
- a uživateli dát k dispozici korpusové frekvence
- v DeriNet 2.1 korpusové frekvence pro lemma+POS z SYN4
- (nový problém: nitroslovnědruhovká homonymie)
- korpusově nedoložená lemmata z MorfFlex.CZ ponecháváme též

Příklady použití korpusových frekvencí

- váhový koeficient při evaluaci
- sampling dávek k ruční anotaci (pro trénování i evaluaci)
 - např. uniformně přes exponenciálně odstupňovaná frekvenční pásma
- zkoumání vlivu frekvence na ...
- příklad: pravděpodobnostní distribuce (svislá osa) délky slova (vodorovná) v jednotlivých frekvenčních pásmech (barva)



Derivace jako strom?

- kladivový zákon
- strom – spojitý acyklický graf
 - derivační vztahy – opravdu spojitý graf?
 - derivační vztahy – opravdu acyklický graf?
- podobné problémy jako u závislotní syntaxe, podobná řešení:
 - umělé fiktivní lexémy (např. *lidnit*, *bízet*, *běhnout*)
 - konvence pro volbu kostry u alternativních cest tvořících cyklus (např. pořadí prefix/suffix u *odčerpání*)
- (po začlenění kompozice je strom samozřejmě neudržitelný)

Z Guinessovy knihy derivačních stromů










- nejhlubší derivační strom:
 - nejhlubší korpusově doložený uzel: *nezpochybnitelnost* v 10. patře
 - nejhlubší nedoložený: *zpochybňovatelčin* v 11. patře
- největší derivační strom
 - největší strom: 1874
 - nejvíce doložených lemmat: 685 (sloveso *stát*)
 - nejvíce nedoložených lemmat: 1291 (*téci*)
- nejvyšší stupeň uzlu (počet přímých derivátů)
 - 41 *řezat*

- souborový formát inspirovaný CoNLL-U
- pythonové API <https://github.com/vidraj/derinet/>
- distribuce dat DeriNetu přes repozitář LINDAT/CLARIAH-CZ
- licence CC BY-NC-SA 3.0

Universal Derivations

- <https://ufal.mff.cuni.cz/universal-derivations>
- UDer 1.1: 31 harmonizovaných derivačních datových zdrojů
<http://hdl.handle.net/11234/1-3247>
 - 21 jazyků
 - rozdílná velikost i kvalita

Universal Derivations



O morfémech

Základní pojmy

- morfém - nejmenší část slova, která nese význam
- morf - konkrétní forma morfému
- alomorfy - různé morfy k témuž morfému

Jak souvisí DeriNet a morfosegmentace?

- derivace a segmentace na morfy: dvě strany téže mince
- prototypicky: jeden derivační krok = jeden přidaný morfém
- ovšem četné asymetrie:
 - některé jiné slovotvorné procesy (kompozice)
 - cirkumfixace
 - konverze
 - flexe

Pro inspiraci několik segmentačních příkladů

Pro inspiraci několik segmentačních příkladů

- *pro inspir-ac-i ně-kolik segment-ač-n-ích pří-klad-ů*

Pro inspiraci několik segmentačních příkladů

- *pro inspir-ac-i ně-kolik segment-ač-n-ích pří-klad-ů*
- *nebo pro in-spir-ac-i ně-kolik seg-ment-ač-n-ích pří-klad-ů ?*

Předchozí výzkum segmentace pro češtinu

- Eleonora Slavičková: *Retrográdní morfematický slovník češtiny*, 1975.
- Zbyněk Šiška: *Bázový morfematický slovník češtiny*, 1998.
- Jiří Lebeda: *Morf-em-at-ic-k-á strukt-ur-a sou-čas-n-é češ-t-in-y*, 2010.
- nicméně: pro češtinu neexistuje moderní datový zdroj s dobrým pokrytím a svobodnou licencí

Vymezení morfému vs. etymologie

- rychlá snadná jasná odpověď: nutno zůstat v synchronním pohledu
- ve skutečnosti přechodná škála bez jasné hranice
 - *leden* – průzračné
 - *pondělek, říjen, nemoc, zločinecký, pořadatel* – hraniční
 - *přítel, manžel, žlutý-zlatý, úterý-vteřina* – určitě mimo synchronní vnímání (alespoň u většiny mluvčích)

Vymezení morfému vs. etymologie (2)

- další problémy:
 - přejímky obecně (vč. novoklasického tvoření) – *privilegium*, *architekt*, *definovat*, *archeologie*
 - pojmenované entity – *Božanov*, *Zdislava*
 - doložená etymologie jde dokonce někdy proti analogii (Panocová 2019)
 - nebezpečí lidové etymologie – *září*, *hřbitov*, *Libeň*, *protežovat*
- závěr:
 - vymezení morfému nelze dokonale objektivizovat
 - těžko oddělitelné od individuální znalosti dalších jazyků a světa vůbec
 - s Wittgensteinem: Hranice mých morfémů jsou hranice mého světa

První průzkum bojem: vlastní anotace

- v tuto chvíli cca 5000 ručně segmentovaných lemmat
- cca 2000 ručně segmentovaných forem

Segmentace a homonymie

- segmentace závislá na zvoleném čtení
 - napříč slovními druhy: *bá-l* vs. *bál*
 - i uvnitř slovního druhu: *od-rol-ov-a-t* vs. *o-drol-ov-a-t*
- homonymie mezi afixy – velmi časté
 - *mír-n-ě* – *kin-ě*
- homonymie afix vs. kořen – méně časté
 - *ech* – *kin-ech*
- dokonce homonymie prefix vs. suffix vs. interfix:
 - *o-tří-t*, *kin-o*, *svět-o-ná-zor*
 - *kin-a* , *a-morál-n-í*, *mlék-a-čti-v-ý*

- některé varianty průzračné: krácení/dloužení
- ale obecně naivní, že by šlo spoléhat na jednoduchou řetězcovou podobnost
- příklady:
 - hláskové změny v kořeni (extrém: *vy-ň-a-v-še* *vy-j-mou-t*)
 - allomorfie v důsledku pravopisu: *u-po-zor-ň-ova-t* vs. *u-po-zor-n-i-t*
- příklady allomorfních skupin:
 - *hlas hlás hláš hlaš hles*
 - *jís jíd jed níd nís něd jez něž*
 - *péc peč pík pék pek píč pec*
 - *svít svit svíc svěc svět svic*
 - *hn žen hán hon háň han hůn hůň*

Překrývání segmentů?

- *český*
- *obléci*

Segmentace a kompozice

- *mil-o-srd-n-ě*
- nelze očekávat, že segmentace kompozita bude přímočaře odpovídat segmentaci vstupních lemma: *jednohrbý*, *blanokřídlý*

Míry pro měření kvality segmentace

- P/R/F1 na morfech
- P/R/F1 na hranicích mezi morfy (morfematický šev)
- procentuální úspěšnost v kompletně správném rozsegmentování slova
- ALE: čím to vážit? asi nutno použít frekvence
- jinak hrozí značné zkreslení (dlouhých slov je více, jsou méně častá, ale pravidelnější a proto na segmentaci snadnější)
- jak přesně? přímo relativní četností? nebo zploštit logaritmem?
- otevřená otázka

Automatická segmentace

- baseline: populární morfosegmentační nástroj Morfessor (Creutz & Lagus 2005)
- s výhodou lze ale využít znalost derivačního stromu (Bodnár 2020):
 - projdu strom od listů nahoru z uzlů do kořene, cestou zpátky zpropaguji nalezené hranice
 - nutno kombinovat s další optimalizací (DL klasifikátor přítomnosti morfematického švu, implementace v TensorFlow)

Method	Morphemes			Boundaries			Words Accuracy
	Precision	Recall	F1	Precision	Recall	F1	
Our method	58.94%	62.62%	63.74%	96.11%	91.63%	93.81%	72.15%
EMmh,i1	64.82%	66.54%	65.67%	91.38%	87.42%	89.36%	35.45%
FlatCat unsup.	37.19%	21.57%	27.31%	97.98%	64.92%	78.10%	1.17%
FlatCat sup.	66.20%	57.72%	61.67%	92.59%	81.15%	86.49%	31.10%

Využití segmentace při hledání v ČNK

- ve spolupráci s Michalem Křenem a Václavem Cvrčkem
- prototyp: kopie syn2015 s přidáním atributem morfeman zachycujícím morfematické hranice a reprezentativní allomorfy
- příklad hodnoty morfeman: |sou:sou:P|hlás:hlas:R|k:k:S|a:a:S|
- dotaz: [morfeman=".:hlas:R.+"]

kontext Dotaz Korpusy Uložit Konkordance Filtr Frekvence Kolokace Zobrazení Nápvěda

Korpus: syn2015_morfeman | Dotaz: .:hlas:R.+ (93 089 výskytů)

Výskytů: 93 089 | i.p.m.: 770,93 (vztaženo k celému korpusu) | ARF: 45 460,33 | Výsledek je seřazen

1 / 2 328

Výběr řádků: základní

☐ Zásas s rodokmenem	nestvůrného řevu , prolomily její mrtvou , černou strnulost a	ohlásily/lo:o:P hlás:hlas:R l:i:i:S t:t:S	blíží se běh . Skutečně už jen za několik málo
☐ Zásas s rodokmenem	se probud ! " vyburcoval mě z mrákot přišerné hluboký	hlas/(hlas:hlas:R	a víčka uvolnila prostor pro tři rozevřené tlamy a
☐ Zásas s rodokmenem	. Jakmile jsem však sevřel chomáč zlostné syčících hadů ,	hlas/(hlas:hlas:R	mě zarazil : " Ne ! To už ti nehrozí
☐ Zásas s rodokmenem	. Táhlý mrtvý pás s bílými skvrnami - hrtan s	hlásivkami/(hlas:hlas:R ivk:ivk:S a:a:S	, svištěcími ve výškách mého tryskového letu . Z
☐ Zásas s rodokmenem	nahmatal zlostné šupinaté kadeře . " Ano , " přitakal	hlas/(hlas:hlas:R	Gorgony , " ale až ve chvíli , kdy jeho
☐ Zásas s rodokmenem	zatlačovat oči rodičům a nabodávat prsty na svíce . Jeho	hlásek/(hlás:hlas:R ek:ek:S	měl onen přesvědčivý tón , kterým malý Ježíš to
☐ Zásas s rodokmenem	mými zády . " Neohlédej se ! " zadržel mě	hlas/(hlas:hlas:R	, jen co jsem pocítil palčivou touhu ještě naposle
☐ Zásas s rodokmenem	sklepů navrtává se střed Země , " uchechtl se studeně	hlas/(hlas:hlas:R	z mošny . Chapadlo zavínuté v zemském jádru .
☐ Zásas s rodokmenem	vyměnění olympánů následkem epidemie nebo strhující záběry z marathónského běhu	hlásatelů/(hlas:hlas:R atel:atel:S	geocentrismu . Veškerý důmysl se drobil na stejn
☐ Zásas s rodokmenem	ti zbývá jen chopit se sekery ! " ozval se	hlas/(hlas:hlas:R	Medúzy , kterou jsem dosud držal za vlasy . "
☐ Zásas s rodokmenem	procesováno enzymy filistrů a hledme , už je možno si	hlásitě/(hlas:hlas:R it:it:S ě:ě:S	odíhnout . Zdá se , že neexistuje duchovní proje
☐ Zásas s rodokmenem	. Nebo by se to taky nevyjasnilo . Takový neodbytný	hlásek/(hlás:hlas:R ek:ek:S	uvnitř tvrdí , že ta epidemie rozostřenosti je práv
☐ Zásas s rodokmenem	ted už by ses nedivil ničemu . Například ani jejímu	hlásu/(hlas:hlas:R	, který zní jako státní hymna New Jersey hraná p

Směrem k "Universal Segmentations"

- pokus o vytvoření zharmonizované kolekce morfosegmentačních dat pro různé jazyky
- hackaton v listopadu 2021: Niyati Bafna, Jan Bodnár, Lukáš Kyjánek, Emil Svoboda, Magda Ševčíková, Jonáš Vidra, Zdeněk Žabokrtský
- v tuto chvíli částečně zharmonizováno cca 20 zdrojů, celkem 150 jazyků, extrémně různá kvalita i velikost dat
- příklady:
 - Ab + bau + ge + recht + ig + keit, Ab + be + ruf + ung
 - advant + age + ous + ly, advers + ari + es
 - a + journe + ment, combatt + ant



Dílčí experimenty související se segmentací

- Jan Bodnár - alomorfie a embeddingy
 - hypotéza: vektorové reprezentace alomorfů by si měly být blízké
- Niyati Bafna - transfer embeddingů z hindštiny do maráťštiny bez paralelních dat
 - hypotéza: EM algoritmus pro indukci bilinguálních embeddingů by mohl fungovat lépe pro morfémy než pro slova
- Ebrahim Ansari - zavedení atomických podřetězců ve fastTextu
 - hypotéza: podřetězce odpovídající morfémům je ve fastTextu efektivnější nedělit na ještě kratší podřetězce

Sci-fi okénko: morfémy a evoluce přirozeného jazyka

- vzdálenější výhled: evoluce jazyka jako migrace morfémů v čase a prostoru
- podobnosti s biologickou evolucí
 - dva předpoklady: rozrůzněnost a selekční tlak
 - konkurence o ekologické niky (například přirozená nutnost vyjádření konatele)
 - evoluci jazyka nelze vidět, jen zpětně rekonstruovat
 - evoluce nemá směr, nelze ji predikovat
- odlišnosti
 - evoluce jazyka – mnohem mnohem rychlejší (homo sapiens cca 10k generací, čeština cca 40 generací mluvčích)
 - "fosilní záznam" vývoje jazyka jen za nepatrné časové období
 - "horizontální přenos morfémů" čtenější než genů

Morfém jako jediný formalizovatelný mem?

- mem
 - jako kulturní analogie genu (Dawkins 1976), replikující se kulturní informace
 - těžko uchopitelná jednotka, memetika některými považovaná za pseudovědu
- morfém - narozdíl od ostatních "memů" relativně diskrétní a atomická jednotka

O paradigmtech

Paradigma v morfologii flektivní a derivační

- flektivní / tvaroslovné paradigma
 - = “soubor tvarů ohebného slova představující systém jeho gramatických kategorií” (Osolsobě, czechency.org, heslo Morfologické paradigma)
- derivační / odvozovací paradigma
 - = lexém a jeho přímé deriváty
 - Furdík (2004: 74nn): “usporiadané súbory komotivátov tvoria akoby sústavu ‘slovotvorných pádov’, ktorú však nemožno pokladať za takú ustálenú, akou je morfológická paradigma”
 - viz Dokulilův (1962: 12nn) termín *slovotvorný svazek*

škol-**a** : škol-**y**.gen-sg

škol-**e**.dat-sg

škol-**u**.acc-sg

škol-**o**.voc-sg

škol-**e**.loc-sg

škol-**ou**.instr-sg

škol(**a**) : škol-**k(a)**.DIMINUTIVE

škol-**n(i)**.RELATION

škol-**sk(ý)**.RELATION2

škol-**ník**.ACTOR/AGENT/PERSON

škol-**ák**.?

Paradigma v morfologii flektivní a derivační

- flektivní / tvaroslovné paradigma
 - = “soubor tvarů ohebného slova představující systém jeho gramatických kategorií” (Osolsobě, czechency.org, heslo Morfologické paradigma)
- derivační / odvozovací paradigma
 - = lexém a jeho přímé deriváty
 - Furdík (2004: 74nn): “usporiadané súbory komotivátov tvoria akoby sústavu ‘slovotvorných pádov’, ktorú však nemožno pokladať za takú ustálenú, akou je morfológická paradigma”
 - viz Dokulilův (1962: 12nn) termín *slovotvorný svazek*

škol-**a** : škol-**y**.gen-sg

škol-**e**.dat-sg

škol-**u**.acc-sg

škol-**o**.voc-sg

škol-**e**.loc-sg

škol-**ou**.instr-sg

škol(a) : škol-**k(a)**.DIMINUTIVE

škol-**n(i)**.RELATION

škol-**sk(ý)**.RELATION2

škol-**ník**.ACTOR/AGENT/PERSON

škol-**ák**.?

Paradigma v morfologii flektivní a derivační

- flektivní / tvaroslovné paradigma
 - = “soubor tvarů ohebného slova představující systém jeho gramatických kategorií” (Osolsobě, czechency.org, heslo Morfologické paradigma)
- derivační / odvozovací paradigma
 - = lexém a jeho přímé deriváty
 - Furdík (2004: 74nn): “usporiadané súbory komotivátov tvoria akoby sústavu ‘slovotvorných pádov’, ktorú však nemožno pokladať za takú ustálenú, akou je morfológická paradigma”
 - viz Dokulilův (1962: 12nn) termín *slovotvorný svazek*

škol-a : škol-y.gen-sg

škol-e.dat-sg

škol-u.acc-sg

škol-o.voc-sg

škol-e.loc-sg

škol-ou.instr-sg

škol(a) : škol-k(a).DIMINUTIVE

škol-n(í).RELATION

škol-sk(ý).RELATION2


škol-ník.ACTOR/AGENT/PERSON

škol-ák.?

Derivační paradigma jako jedna dimenze derivační sítě

Körtvélyessy et al.: *Derivational Networks across Languages*. De Gruyter 2020.

- 30 nemotivovaných slov a jejich přímé i nepřímé **deriváty** ve 40 evropských jazycích
 - 10 substantiv: *bone, eye, tooth, day, dog, louse, fire, stone, water, name*
 - 10 sloves: *cut, dig, pull, throw, give, hold, sew, burn, drink, know*
 - 10 adjektiv: *bad, new, black, straight, warm, old, long, thin, thick, narrow*
- tři dimenze derivační sítě
 1. deriváty uspořádané do derivačních paradigmat = vertikální dimenze
 2. deriváty uspořádané do derivačních řad = horizontální dimenze
 3. deriváty ohodnoceny sémantickou kategorií (Bagasheva 2017)



Paradigma pouze v derivaci? Slovtvorné paradigma

- Štekauer (2014: 369)
 - “It may be assumed that the concept of the derivational paradigm is restricted to affixation in terms of word-formation processes participating in its constitution. ... [T]he idea of a derivational paradigm, constituted by all word-formation processes, is paradigmatically vacuous because it does not lead to a predictable and regularly organized system of complex words.”
- Dokulil (1962: 14)

- *slovtvorné paradigma* = souhrn všech typů úměr napříč slovtvornými hnízdy
– úměry mezi *slovtvornými řadami*:

<i>list</i>	>	<i>lístek</i>	>	<i>lístkový</i>	>	<i>lístkovitý</i>
<i>květ</i>	>	<i>kvítek</i>	>	<i>kvítkový</i>	>	<i>kvítkovitý</i>


- úměry mezi *slovtvornými svazky*:

<i>medvěd</i>	>	<i>medvědí</i>	<i>slon</i>	>	<i>sloní</i>	<i>velbloud</i>	>	<i>velbloudí</i>
		> <i>medvídě</i>			> <i>slůně</i>			> <i>velbloudě</i>
		> <i>medvědice</i>			> <i>slonice</i>			> <i>velbloudice</i>

- Fernández-Domínguez a kol. (2020): paradigmata v kompozici atd.

Slovotvorné paradigma se členy vymezenými sémanticky

- Bauer (2019: 156)
 - *paradigm of functions*: “Sometimes, the precise form which will be found in a paradigm is not predictable, but we can predict the presence of a form to fill that particular function.”
- Bonami & Strnadová (2019)
 - *paradigma* = sada lexémů, které v daném hnízde vyjadřují určité sémantické kategorie
 - slovotvorný proces ani formant nebrány v potaz
 - nezahrnuje všechny členy hnízda
 - každý člen spojen s každým
 - nerozlišován motivující vs. motivovaný člen (hrany nejsou orientované)
 - *paradigmatický systém* = soubor paradigmat napříč hnízdy



<i>propose</i>	<i>proposal</i> .ACTION	<i>proposer</i> .AGENT
<i>inspect</i>	<i>inspection</i> .ACTION	<i>inspecter</i> .AGENT
<i>protest</i>	<i>protest</i> .ACTION	<i>protester</i> .AGENT

- srovnávací studie čeština vs. angličtina
- dvojice substantiva a slovesa utvořené bez derivačního materiálu
 - v češtině rozdíl ve flektivních morfémech (téma a infinitivní koncovka u slovesa)
start-ova-t : *start* = konverze / transflexe / derivace (Ševčíková, v tisku)
 - angl. substantivum a sloveso mají formálně totožný slovníkový tvar
start.v : *start.n* = konverze (Valera, 2015)
- paradigmatický přístup
 - konverzní dvojice uskupeny podle sémantického vztahu mezi subst. a slovesem
 - bez ohledu na směr tvoření (sloveso > subst vs. subst < sloveso)
 - *experiment* > *experimentovat* (= dělat experimenty)
experiment.n > *experiment.v* (= to make an experiment upon)
 - *revise* > *revidovat* (= konat revizi)
revise.n (= the action of revising) < *revise.v*

Ševčíková & Hledíková, forth.

Cizí slova v češtině: agentní a dějové substantivum

- 165 dvojic sloves a formálně totožných substantiv z British National Corpus
- jejich přímé protějšky v češtině extrahovány ze SYN2000
 - v češtině a v angl. v jednotlivých dvojicích stejný sémantický vztah
- konverzní dvojice analyzovány spolu s agentním a dějovým substantivem

<i>telefonovat</i>	<i>telefon</i> .INSTR	<i>telefonista</i> .AGENT	<i>telefonát</i> .ACTION
<i>telephone.v</i>	<i>telephone</i> .n.INSTR	<i>telephonist</i> .AGENT	X
<i>filtrovat</i>	<i>filtr</i> .INSTR	X	<i>filtrace</i> .ACTION
<i>filter.v</i>	<i>filter</i> .n.INSTR	X	<i>filtration</i> .ACTION
<i>extrahovat</i>	<i>extrakt</i> .RESULT	X	<i>extrakce</i> .ACTION
<i>extract.v</i>	<i>extract</i> .n.RESULT	<i>extractor</i> .AGENT	<i>extraction</i> .ACTION
<i>ruinovat</i>	<i>ruina</i> .RESULT	X	<i>ruinace</i> .ACTION
<i>ruin.v</i>	<i>ruin</i> .n.RESULT	X	<i>ruination</i> .ACTION

Cizí slova v češtině: tendence k nominálnímu vyjadřování

- agentní jméno v češtině nedoloženo, i když cizí protějšek k dispozici
- dějové substantivum v češtině k dispozici, i když angl. protějšek chybí

<i>atakovat</i>	<i>atak</i>	X
<i>attack.v</i>	<i>attack.n</i>	<i>attacker.AGENT</i>
<i>transportovat</i>	<i>transport</i>	X
<i>transport.v</i>	<i>transport.n</i>	<i>transporter.AGENT</i>
<i>skórovat</i>	<i>skóre</i>	X
<i>score.v</i>	<i>score.n</i>	<i>scorer.AGENT</i>

<i>telefonovat</i>	<i>telefon</i>	<i>telefonát.ACTION</i>
<i>telephone.v</i>	<i>telephone.n</i>	X
<i>parfémovat</i>	<i>parfém</i>	<i>parfemace.ACTION</i>
<i>perfume.v</i>	<i>perfume.n</i>	X
<i>archivovat</i>	<i>archiv</i>	<i>archivace.ACTION</i>
<i>archive.v</i>	<i>archive.n</i>	X

- v některých hnízdech v češtině sloveso chybí úplně
 - substantivum jako jediný prostředek pro vyjádření dějového významu

X	<i>kremace.ACTION</i>
<i>cremate</i>	<i>cremation.ACTION</i>
X	<i>demise.ACTION</i>
<i>demit</i>	<i>demission.ACTION</i>

X	<i>infuze.ACTION</i>
<i>infuse</i>	<i>infusion.ACTION</i>
X	<i>incidence.ACTION</i>
<i>incide</i>	<i>incidence.ACTION</i>

Vid u denominativních vs. nemotivovaných (a deverb.) sloves

- většina cizích sloves v češtině kompatibilní s jedinou kmenotvornou příponou
 - vidový protějšek tvořen předponou nebo netvořen vůbec (obouvidovost)
test-ova-t > *o-test-ova-t*, *balet-i-t*, *explod-ova-t*
 - dvě témata u malé skupiny cizích sloves
klik-a-t : *klik-nou-t*, *risk-ova-t* : *risk-nou-t*
- u domácích sloves kompatibilita s jediným tématem typická pro denominativa
 - vidový protějšek tvořen předponou
(*noc* >) *noc-ova-t* > *pře-noc-ova-t*, (*sůl* >) *sol-i-t* > *o-sol-i-t*
- domácí nemotivovaná slovesa (a deverbativní slovesa)
 - tvoření vidového protějšku změnou kmenotvorné přípony
 - motivují bezpříponová substantiva
skák-a-t : *skoč-i-t* (> *skok*), *od-káz-a-t* : *od-kaz-ova-t* (> *odkaz*)

Deverbativní bezpříponová substantiva vs. slovesa utvořená od bezpříponových substantiv

<i>skoč-i-t</i>	>	<i>skok</i>
<i>pot-i-t</i>	<	<i>pot</i>
<i>soud-i-t</i>	?	<i>soud</i>

- dvojice slovesa a bezpříponového substantiva jako součást paradigmatu
 - vidový protějšek s odlišným tématem jako zvláštní slot
 - rozdíly v doloženosti bezpříponových substantiv

<i>skákat</i>	<i>skočit</i>	<i>skok</i>	<i>vyskočit</i>	<i>vyskakovat</i>	<i>výskok</i>
<i>křičet</i>	<i>křiknout</i>	<i>křik</i>	<i>vykřiknout</i>	<i>vykřikovat</i>	<i>výkřik</i>
<i>potit</i>	X	<i>pot</i>	<i>zpotit</i>	X	X
<i>prášit</i>	X	<i>prach</i>	<i>oprášit</i>	<i>oprašovat</i>	X
<i>listovat</i>	X	<i>list</i>	<i>prolistovat</i>	<i>prolistovávat</i>	X
<i>soudit</i>	X	<i>soud</i>	<i>odsoudit</i>	<i>odsuzovat</i>	X

- určení směru tvoření podle paradigmatu

Ševčíková 2021, Ševčíková, v tisku

Konatelská/činitelská jména v češtině

<i>sjednot-i-tel</i>	X	<i>sjednot-i-t</i>	X	X
<i>sjednoc-ova-tel</i>	<i>sjednoc-ova-t</i>	X	X	X
<i>model-ář</i>	<i>model-ova-t</i>	X	<i>model</i>	X
<i>zvon-ík</i>	<i>zvon-i-t</i>	X	<i>zvon</i>	X
<i>závod/n/ík</i>	<i>závod-i-t</i>	X	<i>závod</i>	<i>závod-n-í</i>
<i>boj-ov/n/ík</i>	<i>boj-ova-t</i>	X	X	<i>boj-ov-n-ý</i>
<i>střel-ec</i>	<i>stříl-e-t</i>	<i>střel-i-t</i>	<i>střel-a</i>	X
<i>kup-ec</i>	<i>kup-ova-t</i>	<i>koup-i-t</i>	<i>koup-ě</i>	X

válečník – válčit – válka – válečný

target_noun_suffix	-ník/-ík
root_final	č
root_final_cvs	consonant
root_final_vertical	africate
root_final_horizont	postalveolar
number_prefixes	0
v1_theme	i
v1_aspect	imp
v1_conjug	4
v1_suf_asp_counterpart	no
v2_theme	–
v2_aspect	–
v2_conjug	–
paradigm_type	NNA-V-
inanim_noun	no
freq_parent_noun	25,895
freq_parent_adj	4,953
freq_parent_v1	499
freq_parent_v2	–
freq_slots	VAN

Ševčíková et al. 2021


Predikce agentního formantu podle paradigmatu

- A: kořen a téma motivujícího slovesa
[root_final, root_final_cvs, root_final_vertical, root_final_horizont, v1_theme, v2_theme]
- B: prefixy, téma, aspekt, konjug. třída motivujícího slovesa
[number_prefixes, v1_theme, v1_aspect, v1_conjug, v2_theme, v2_aspect, v2_conjug]
- C: paradigma [paradigm_type, v1_suf_asp_counterpart, inanim_noun]
- D: korpusová frekvence [freq_parent_noun, freq_parent_adj, freq_parent_v1, freq_parent_v2, freq_slots]

sufix	subst.	všechny rysy (log.regr./dec.trees)	A	B	C	D
-tel	85	0.69/0.71	0.32/0.40	0.66/0.67	0.63/0.63	0.39/0.45
-č	77	0.71/0.66	0.55/0.51	0.54/0.50	0.10/0.10	0.59/0.29
-ník/-ík	21	0.63/0.65	0.21/0.29	0.00/0.09	0.78/0.78	0.72/0.65
-ář/-ař	19	0.56/0.53	0.34/0.39	0.29/0.27	0.53/0.61	0.56/0.42
-ce	13	0.38/0.46	0.22/0.36	0.47/0.48	0.44/0.33	0.45/0.48
-ák	10	0.25/0.27	0.17/0.27	0.21/0.21	0.31/0.31	0.00/0.07
-ec	6	0.40/0.62	0.18/0.21	0.15/0.15	0.13/0.10	0.60/0.14
-čí	2	0.25/0.33	0.15/0.17	0.14/0.13	0.00/0.17	0.00/0.00
všechny suf	233	0.63/0.63	0.37/0.41	0.48/0.48	0.42/0.42	0.49/0.39

Slovotvorná paradigmatata v DeriNetu?

- ? ParaDeriNet
 - apriorně stanovená paradigmatata plnit lexikálním materiálem
 - inspirace ve zdrojích pro jiné jazyky
- spíše: do stávajících dat doplnit sémantické značky
- pilotní experiment
 - 5 sémantických kategorií
 - DIMINUTIVE, FEMALE, POSSESSIVE, ITERATIVE, ASPECT
 - poloautomatická procedura
 - rodič ve stromě, slovní druh, gramatické kategorie (rod, vid)



(Namer & Hathout 2020)

Ševčíková & Kyjánek 2019

Závěrečné poznámky

Další nedávné experimentální linie kolem DeriNetu

- Emil Svoboda - modelování kompozice
- Kristýna Neumannová - modelování univverbizace
- Lukáš Kyjánek - kompilace derivačních zdrojů pro ruštinu
- Jonáš Vidra - crosslingvální transfer derivačních stromů

Děkujeme!

- Bauer, L. (2019). Notions of paradigm and their value in word-formation. *Word Structure* 12:153–175.
- Bodnár, J. (2020)
- Bonami, O. & Strnadová, J. (2019). Paradigm structure and predictability in derivational morphology. *Morphology*, 29:167–19.
- Creutz & Lagus (2005)
- Dawkins (1976)
- Dokulil, M. (1962). *Tvoření slov v češtině I*. Academia.
- Fernández-Domínguez, J. et al. (2020). *Paradigmatic Relations in Word Formation*. Brill.
- Furdík, J. (2004). *Slovenská slovo tvorba*. Náuka.
- Hajič, J. & Hlaváčová, J. (2013). *MorfFlex CZ*. LINDAT/CLARIN digital library at ÚFAL MFF UK, <http://hdl.handle.net/11858/00-097C-0000-0015-A780-9>
- Namer, F. & Hathout, N. (2020): ParaDis and Démonette. From Theory to Resources for Derivational Paradigms. *The Prague Bulletin of Mathematical Linguistics*, 114:5–33.
- Panocová, R. (2017). Internationalisms with the Suffix *-ácia* and their Adaptation in Slovak. In *Proceedings of DeriMo*. EDUCatt, 61–72.
- Ševčíková, M. (2021):). Action nouns vs. nouns as bases for denominal verbs in Czech. *Word Structure*, 14:97–128, <https://www.eupublishing.com/doi/full/10.3366/word.2021.0181>
- Ševčíková, M. (v tisku): Bezpříponová substantiva a vyjadřování vidového protikladu u příbuzných sloves. *Slovo a slovesnost*.
- Ševčíková, M. & Hledíková, H. (forth.): Paradigms in English and Czech noun/verb conversion: A contrastive study of corresponding lexemes. In *Paradigms in word formation: Theory and applications*. Benjamins.
- Ševčíková, M. & Kyjánek, L. (2019): Introducing Semantic Labels into the DeriNet Network. *Jazykovedný časopis* 70:412–423.
- Ševčíková, M. et al. (2021): Agent noun formation in Czech. Presented at ParadigMo 2021, <http://paradigmo2.eklablog.com/program-c31046450>
- Štekauer, P. (2014). Derivational paradigms. In *The Oxford Handbook of Derivational Morphology*. OUP, 354–369.
- Valera, S. (2015). Conversion. In *Word-Formation. An International Handbook of the Languages of Europe*, Vol 1. De Gruyter, 322–339.