

HiČKoK: History of Czech in Corpus Continuum

Daniel Zeman

📅 December 9, 2024



Historie češtiny
v korpusovém
kontinuu

Three-year project (September 2023 – November 2026)



Funded by TAČR

Carried out by



Národní knihovna
České republiky
National Library
of the Czech Republic



Historie češtiny
v korpusovém
kontinuu

Three-year project (September 2023 – November 2026)



Funded by TAČR

Carried out by



Národní knihovna
České republiky
National Library
of the Czech Republic

Outline

- 1 Goals
- 2 Old Czech: Workflow
- 3 Old Czech: Interesting Issues

Goals

Výběr řádků: základní ▾

zalakovaná , za což jsi velice vděčný . </p><p> A hopla jednoho jsou tak akorát pro hladovce , na chodbě se to máš nechat plavat . Zatímco jsi byl pryč , měla barvy pšenice , aspoň tak sis to představoval ; že by sis ji mohl s Dolly spojovat . </p><p> je svým lehkomyslným způsobem velkorysý . " Máte k sobě tam našla chyby ? " </p><p> Má seznam krásné po ruce Alex Hardy . Vážně pokývne hlavou , jako byste právě peníze z pojistky - jistě jejen , že zmizely stříbrnými vlasy pečlivě zkoumá tvou pozvánku . Po stranách dveří paměti a pátráš po nějakých stopách . </p><p> Ve vrchním šuplíku . Kreditní kartou ho vyškrábneš na stůl a kartou také , že má rozkošný zadeček . Děláš jsi s ní je velká a lesklá a je na ní mladší Megan ten česnek , " zeptá se . Podařilo se ti radši natáhl . Zabořit se hlavou Megan do klína a že věkem bude ještě pod zákonem . Pod očima si mu zatřeseš ramenem . Zaboří se obličejem do polštáře . <p> " Je to pravda . Musel jsem s téma numerama . " </p><p> V koutě podlaží je bokem několik pokojíků . zotročit , že myslí i na jiné věci . Ukrojila li nyní začít svou zpověď , musím si p dobré . Hřichů má špatná vláda mnoho , a jsem tam mnohemokrát a pokaždé jsem si odtamtud a to právě v papežském paláci . Stanuly kulařky stůl v kolbiště prudkých střetů . N	.,/Z:----- dva/dva/CLIP1----- ,/Z:----- tři , čtyři . Vojáci už se postavili na nohy .</p><p> Pluješ po linoleu do Oddělení verifikace , jeden od jakéhosi monsieura z oddělení čehosi a v Kansasu jsi ještě žádnou pšenici neviděl . Většin později byla Dolly pozvaná na svatbu na východě . blízko , " chceš vědět . </p><p> " Podle mě je přízvuky , volební obvod ve střední Francii nespráv osobami , které hodlá najít o půlnoci v Klářině kanc . </p><p> U vchodu vysoká žena se stříbrnými vlas černoši v turbanech a paže mají zkřížené na prsou obdélníkové balíčky . Jeden z nich vlastně úplně prádky . Podíváš se na Megan . Čte . Klidně a vůbec sis té nádhery nevšiml . Kolik jí vlastně na jevišti . </p><p> " To byla moje poslední role . Jsou pěkně nahaté . </p><p> " Moc výkonné zrov zůstat . Postel jejen pár kroků odsud . Nakloníš prázdné/objevit/VB-S---2P-AA---P dva/dva/CLIP4----- prázdné/prázdný/AAP4---1A----> oloupat/oloupat/Vf-----A---P dva/dva/CLIP4----- stroužky/stroužek>NNIP4---A----> týden/týden/NNIS4---A--- dva/dva/CLIP1----- tak/tak/Db-----> purpurové/purpurový/AAP4---1A----> rádky/rádek/NNIP4---A----> večery/večer/NNIP1---A----> jsou/být/VB-P---3P-AA---I ti/ty/PH-S3---2----- dva/dva/CLIP4----- tlusté/tlustý/AAP4---1A---->	vyhnou/vyhnut/VB-P---3P-AA---P dva/dva/CLIP1----- chodci/chodec/NNMP1---A----> brala;brát/VpFS---R-AA---I dva/dva/CLIP4----- vzkazy/vzkaz/NNIP4---A----> za/za/RR---4----- dva/dva/CLIP4----- měsíce/měsíc/NNIP4---A----> O/o/RR---4----- dva/dva/CLIP4----- roky/rok/NNIP4---A----> vy/vy/PP-P1---2----- dva/dva/CLIP1----- hodně/hodně/Dg-----1A----> :/Z:----- dva/dva/CLIP4----- opačné/opačný/AAP4---1A----> vy/vy/PP-P1---2----- dva/dva/CLIP4----- byli/být/VpMP---R-AA---I za/za/RR---4----- dva/dva/CLIP4----- týdny/týden/NNIP4---A----> stoji/stát/VB-P---3P-AA---B dva/dva/CLIP1----- ohromný/ohromný/AAMP1---1A----> objeviš/objevit/VB-S---2P-AA---P dva/dva/CLIP4----- prázdné/prázdný/AAP4---1A----> uděláš/udělat/VB-S---2P-AA---P dva/dva/CLIP4----- rovné/rovný/AAFP4---1A----> skoro/skoro/Db----- dva/dva/CLIP4----- roky/rok/NNIP4---A----> a/a/J^----- dva/dva/CLIP1----- muži/muž/NNMP1---A----> oloupat/oloupat/Vf-----A---P dva/dva/CLIP4----- stroužky/stroužek>NNIP4---A----> týden/týden/NNIS4---A--- dva/dva/CLIP1----- tak/tak/Db-----> purpurové/purpurový/AAP4---1A----> rádky/rádek/NNIP4---A----> bejt/být/Vf-----A---6I dva/dva/CLIP1----- večery/večer/NNIP1---A----> První/první/CrMP1----- dva/dva/CLIP1----- jsou/být/VB-P---3P-AA---I ti/ty/PH-S3---2----- dva/dva/CLIP4----- tlusté/tlustý/AAP4---1A---->
		▲ Knoflík na dveřích se otáčí sem a tam . Allagash tě štoučá do ruky a rty se horečně vyptává . Zámek cvakne a dveře se rozletí . Stojí v nich Alex Hardy . Vážně pokývne hlavou , jako byste právě vy dva byli osobami , které hodlá najít o půlnoci v Klářině kanceláři . Snažíš se rychle vymyslet povídáčku , kterou by spolk . Tad třímá dřevěný metr , který našel za dveřmi . </p><p> " Ty jsi nás , Alexi , vylekal . ▼
		zistat/Vf-----A---P dva/dva/CLIP4----- lipomínat lícní kosti . Už víš a sedně si do kresla . Dnes je to přesně za sebou a samozřejmě , že expres Allagash vykole plné kokainových fandů a seriózních žvaniliů . Třetí krajice . Kůrku měly spálenou , ale uvnitř byly navlh , které mám obzvlášť rád . " Velikou , tajemnou : pošlapání Spravedlnosti a vláda Tyranie . Ty ostat dojmy : hlučný sobotní trh , rozpínající se po městě , filoanjourouvský , který navrhoval francouzského ka a stále ještě nebylo vidět světlo habemus padam 3/31

Výběr řádků: základní ▾

Inga Čebele Ostřice Hra o	dvoù/NUM/Case=Loc Number=Plur NumForm=Word NumType=Card	dějstvích Osoby Vilhelms Putns Lja , jeho ze
zmlkne .) A tak dál a tak dál .	Dvě/NUM/Case=Nom Gender=Fem Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	stránky a fotografie . Všichni to čtou , celé m
vinář ke mně přišel s lahví koňaku , že jsem	dva/NUM/Animacy=Inan Case=Acc Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	dny nejedla ... , hodně toho tam není napsáno
. Lja . Aleksisi , přečti ještě něco . Ti	dva/NUM/Animacy=Anim Case=Nom Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	už mě omrzeli . leva přistoupí ke stolu a seb
Vilhelms . Ted' je to snad v pořádku . Už	dva/NUM/Animacy=Inan Case=Acc Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	roky je pryč . Ted' si ho sem přivolala maminka
děje jenom na naší čtvrti . Lja . Měla jsem	dva/NUM/Animacy=Anim Case=Acc Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	syny – vlastního Aleksise a ještě jednoho . V
Aleksis . To je teda vážně ostuda . A já	dva/NUM/Animacy=Inan Case=Acc Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	roky žil jak anděl . Santa (Usměje se ,
knek do tmy . Hledá cigarety , ale najde jen	Dvě/NUM/Case=Acc Gender=Fem Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	prázdné krabičky . Zapíná rádio . Přelaďuje s
... Ale neřekla jsem ti , že ve skutečnosti už	dva/NUM/Animacy=Inan Case=Acc Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	měsíce žiju s jiným týpkem , jo , no ,
i vyštourával zbytky sena . Po jednom či po	dvoù/NUM/Case=Loc Number=Plur NumForm=Word NumType=Card	se děti vracejí zpět k autu a sypaly otci do
ocí stisk čelistí . Na břehu ležely na dekách	Dvě/NUM/Case=Nom Gender=Fem Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	tělnaté ženy a vitaly oba příchozí . U nikoho :
dcer a syn , žena , muž a sestra ,	Dvě/NUM/Case=Nom Gender=Fem Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	sestry s bratrem nebo otec s dvěma dcerami
a sestra , dvě sestry s bratrem nebo otcem s	Dvěma/NUM/Animacy=Inan Case=Ins Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	dcerami . Jejich radost a výkřiky byly urputné
lo malého města , vrásčitá , unavená žena s	Dvěma/NUM/Animacy=Inan Case=Ins Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	nevychovanými syny . Pracovala jako poštač
mlíčky . Bertolds udělal jeden krok , chlapec	dva/NUM/Animacy=Anim Case=Nom Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	. V každé ruce se mu pohupoval sandál . Za
ejme , že jsem ještě nic nepropásl . Koupím	Dvě/NUM/Case=Acc Gender=Neut Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	pořádná kola , stan a vezmu si dovolenou . F
. Spěchaly dál přes hřbitov . U vchodu , kde	Dvě/NUM/Case=Nom Gender=Fem Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	borovice připomínaly tajemný vstup na onen
prohodila to jen tak , mezi řečí , možná mezi	Dvěma/NUM/Animacy=Inan Case=Ins Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	sklenkami vína . Ale moje fantazie už začala
jet do Buenos Aires . , K tomu musej bez	dva/NUM/Animacy=Anim Case=Nom Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	„ , přerušil ji vždycky muž , který tu teď
yho všimnul a ocenil ho , k tomu musej bez	Dvě/NUM/Animacy=Anim Case=Nom Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	. ~ # ~ Regina se odmlčí , nanovo se
že pozoruje každý její pohyb . Bílá skvrna se	Dvěma/NUM/Animacy=Inan Case=Ins Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	zhnoucíma , dehtově černýma očima na vzor
Nechce se jim bez ní odejít . Pokládají ji na	dve/NL	suché smrkové větve tak , aby se očními otv
ed očima . Nazelenalá kost orámuje krajину	Dvěma/NUM/Animacy=Inan Case=Ins Gender=Masc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	okny . Jsou tak široká , že se musí dívat
sklem auta , tento spánek vysvětlí vizi o nich	dvoù/NUM/Animacy=Anim Case=Loc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	, o ní a Pávillovi v prvotním lese , ukázel
chalupu . Potraviny spravedlivě rozdělili do	dvoù/NUM/Animacy=Anim Case=Loc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	baťohů , jen dočerna vyuzený kančí hřbet vza
ela si s obavami leva a neslyšela žádné raz	dva/NUM/Animacy=Anim Case=Loc Number=Plur NumForm=Word NumType=Card NumValue=1 NumValue=2 NumValue=3	tří . Ve světle reflektorek viděla Pávillovu tvor

Výchozí zobrazení | Formátovaný text

Výběr řádků: základní ▾

<input type="checkbox"/> 1492	mi se , že jest . V tom městě byli	sme dva dní	, chleba vody i rozličného vovoce bylo co dosti kúpiti
<input type="checkbox"/> 1492	i na vodu , neb do něho teče sedmdesát potokov	a dva .	Pak na kupecké věci jest převelmi bohaté , ješto na
<input type="checkbox"/> 1492	. Pak opět dne jiného ráno vstavše , šli se	mnú dva bosáci	do Jeruzaléma , neb hora Sion jest od Jeruzaléma jako
<input type="checkbox"/> 1492	kus zdi kostelnie , a tak mi pravili , že	zabilo dva černé	křestany , a nedadie jim toho zase opravit . V
<input type="checkbox"/> 1492	ješto držíe křest , světie toliko neděli , ti mají	jedno dva štrychy	nebo znamenie na tváři . Třetí toliko držíe křest ,
<input type="checkbox"/> 1492	a některé muož tluščie býti . Vinic nekopají , ale	zapráha dva buvol	do pluhu i obvorávají je na všecky strany , totižto
<input type="checkbox"/> 1492	vašeho . V Gaze byli sme týden . Odtud sme	jeli dva dní	i přijeli sme k jednomu městečku a neviděli sme ho
<input type="checkbox"/> 1492	daktylov jako chmele , že jich z toho kolečka natrhá	se dva věrtle	a z druhého viec . A na jednom dřevě bude
<input type="checkbox"/> 1492	toho voda z trub teče . A u toho koryta	sedítia dva starci	a ktož koli přijde k té mříži a chce piti
<input type="checkbox"/> 1492	, a když sem toho pilen byl , potom mi	poručil dva a	tak dále , až mi i jiné věci poručel .
<input type="checkbox"/> 1492	byla , tehdy na osle jede a okolo nie jdú	služebníci dva nebo	třie a tvář jejé jest všecka zakryta čistým tafartem černým
<input type="checkbox"/> 1492	a netoliko já , ale všichni kupci . Byla se	nám dva pacholky	roznemohla , kteréžto tajně mezi sebú chovali sme a nemocné
<input type="checkbox"/> 1835	ještě vypravoval , kdyby ho příchozí nebyli vytrhlí . Byli	to dva cikáni	. Napřed šel malý , po maďarsku vystrojený mladík ,
<input type="checkbox"/> 1835	Mladý cikán postoupil , spatřiv vysloužence a ostatní , zaražený	as dva kroky	zpět , jako by byl někoho jiného očekával ; opět
<input type="checkbox"/> 1835	mezi křívoum nějakou rozsedlinou dolů . Starší lezl za ním	asi dva sáhy	hluboko , a oba stanuli v skalnaté kotlině asi dva
<input type="checkbox"/> 1835	dva sáhy hluboko , a oba stanuli v skalnaté kotlině	asi dva sáhy	dlouhé a sáh široké . Kolem nich strměla písečná skála
<input type="checkbox"/> 1835	se vám vracím jednou domů ; jest to ode dneška	za dva měsíce	osm let , já jsem si to zapsal . -
<input type="checkbox"/> 1835	a ještě jeden šli před nimi s rozžatými pochodemni .	Ostatní dva ,	pomohše jim mrtvol přendati přes kostničí kámen , šli ozbrojeni
<input type="checkbox"/> 1835	prsa a zaclánělo hlubokou ránu jejich . Zachvěl se cikán	; dva rychlé	kroky přistoupil blíže a po jeho nad hlavu vyzdvižené pravici
<input type="checkbox"/> 1835	tlačilo nesčíslné množství vůkolního lidu . Na nejvyšším jeho vrcholku	stály dva mladé	stromky , uprostřed nich strměl čekan a kolem toho se
<input type="checkbox"/> 1835	straně kněž . po druhé místě napravil . Za ním	vedli dva pacholci	hláznivou Angelou uvázanou na dlouhém provaze , která do výšky
<input type="checkbox"/> 1792	▲ na palmě , neb když z daleka na ně hledí , zdá se jako voháňka , pak v tom větví sú		X přišli , kterouž ona podlé
<input type="checkbox"/> 1792	kola vyrostlá jako melé a na tom melí bude daktylov jako chmele , že jich z toho kolečka		j zlatý Radoji , jak
<input type="checkbox"/> 1869	natrhá se dva věrtle a z druhého viec . A na jednom dřevě bude takových kol čtyři nebo		výtiscích ještě na skladě . Belletristický
<input type="checkbox"/> 1869	pět . Také v tom městečku zdá mi se , že najvětšie živnost jich jest daktyle , neb odtud		
<input type="checkbox"/> 1869	dodávají daktylov do všech zemí okolních kupci ▼		

▲ na palmě , neb když z daleka na ně hledí , zdá se jako voháňka , pak v tom větví sú kola vyrostlá jako melé a na tom melí bude daktylov jako chmele , že jich z toho kolečka natrhá se dva věrtle a z druhého viec . A na jednom dřevě bude takových kol čtyři nebo pět . Také v tom městečku zdá mi se , že najvětšie živnost jich jest daktyle , neb odtud dodávají daktylov do všech zemí okolních kupci ▼



přišli , kterouž ona podlé

j zlatý Radoji , jak

výtiscích ještě na skladě . Belletristický

dva

Hledej

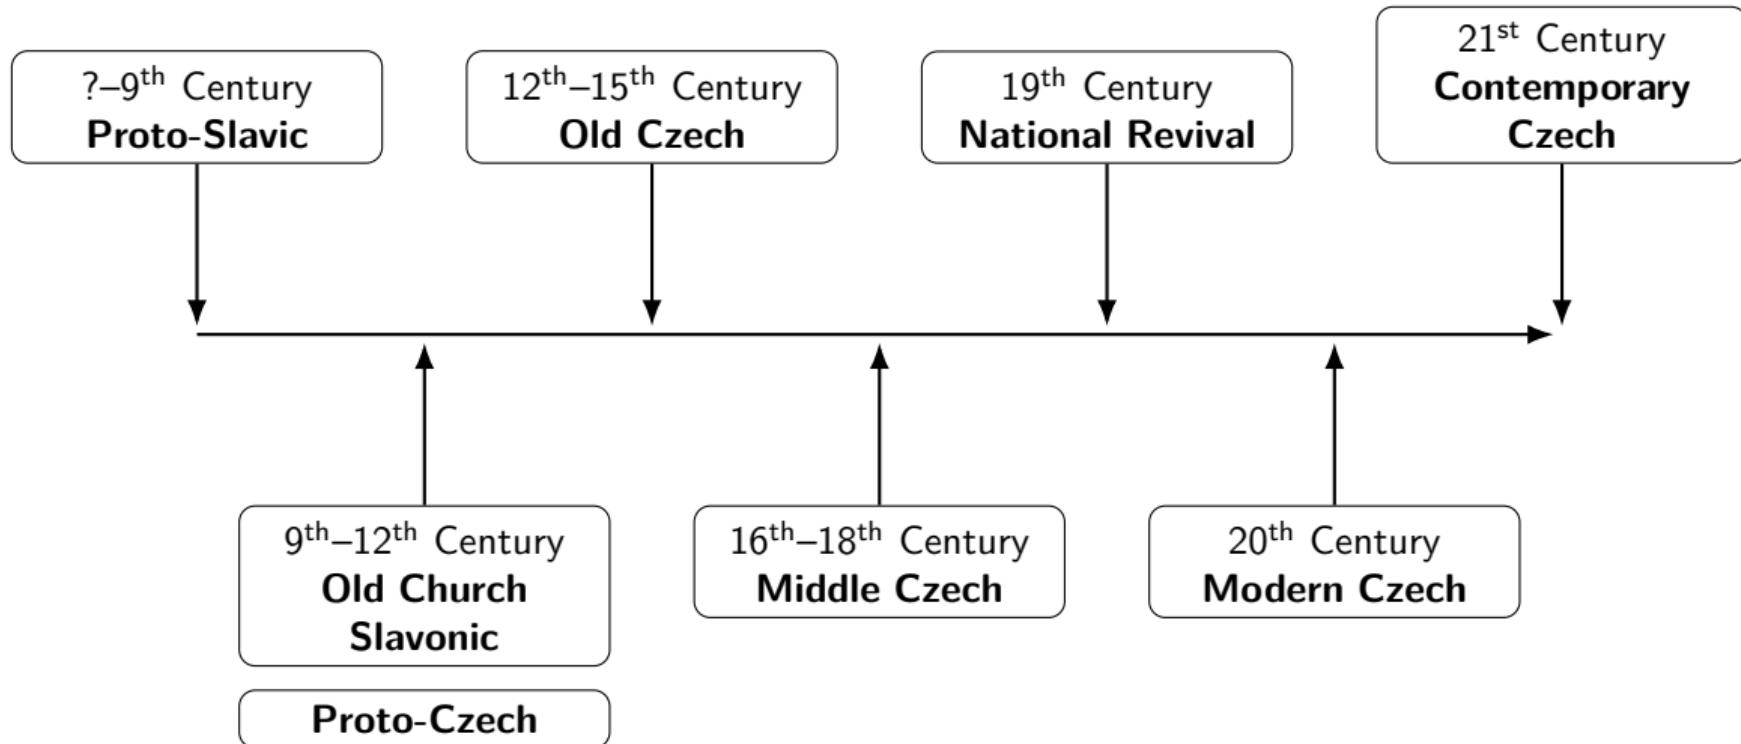
dva	měsíc ; dnem i nocí bez přestání nódpočinu šturmování ; jakž obirtli tako praky , nódpočinuce čas vša
dva	... deset tisícov . Však proto , že böh ... prodal jé a hospodin zaklopil jé . Nenie vedé böh naš jako bohov
dva	však , ale jeden jest Kristus . Jeden zajisté ne obrácením božství v tělo , ale přijetím člověčství u bož .
dva	voly vylúdī . Jako byl jeden učinil vládyka , že byl vylúdil dva voly , s hnědým plavého , u svého kmetě d
dva	voly , s hnědým plavého , u svého kmetě dobrého , jehož obviniti chtieše , ale sličně nemožieše . Pozvav ji
dva	voly jmám , oba na ofěř prodám , na vosku a na přikrově , v némžto mě pohřebu v rově . „ Ješe máš d
dva	dni bojováše , prosě za vše své milé syny , aby Böh spustil jich viny , i za jiné , ktož budú jeho sluhy , aby
dva	a sedmdesát sěoci vzbudi ; smrt vsed... na jeho hrudi , hned z něho duši vypudi . Tak sě on svých hi
dva	anděly z nebe u bielém rúš blíz sebe , vniž k hlavě a k nohám piece , nevzdál ot sebe sediece . Otázasta ji
dva	zloděje s ním vediechu , nad nimažto popravit chtiechu . Když Ježuš vyvedú z města na popravu , tehdы
Dva	biešta dlužna jednomu lichevniku , jeden bieše dlužen patset peněz a druhý patdesát . A když nejmějšeta c
dva	modlitbi . I stala sě jest krása jeho obličejē jinaká , když sě modléše , a jeho rúcho bielé stkvieše sě . A tehdы
dva	mužě mluviešta s ním . A to biešta Mojžieš a Heliáš , viděna u veleslavenství , a mluviešta o jeho přihodě
dva	mužě , ješto s ním stojiešta . I stalo sě jest , když otjidešta ot řeho ta dva mužě , vecě Petr k Ježiševi : „ Př
dva	mužě , vecě Petr k Ježiševi : „ Přikazateli , dobré jest nám tuto býti . A učiňme tři stany : jeden tobě a jede
dva	a sedmdesát i rozesla jě po dvou do každého města všudy , kamž jmějše sám přijiti . I mluvieše jim : „ Jis
dva	a sedmdesát učedníkuov s radostí řkuce : „ Hospodine , také i běsové jsú nám poddání ve jmě tvé . „ I vec
dva	najazd . i do otrubu řka : Tmáč ijm ráči , a což koli nař naložíš . iáz ledur cā vrátim . vráni tobě . Kto z tě

doc Bible drážďanská, Lukášovo evangelium; 2. polovina 60. let 14. století; rukopis; Německo; Drážďany; Saská státní knihovna – Státní a univerzitní knihovna v Drážďanech (Die Sächsische Landesbibliothek – Staats- und Universitätsbibliothek Dresden); Mscr.Dresd.Oe.85; 14; Bibl; BiblDrážď; próza; biblický text; [ediční poznámka](#); Hlaváčová Svobodová, Andrea (Ústav pro jazyk český AV ČR, v. v. i.) – Voleková, Kateřina (Ústav pro jazyk český AV ČR, v. v. i.)

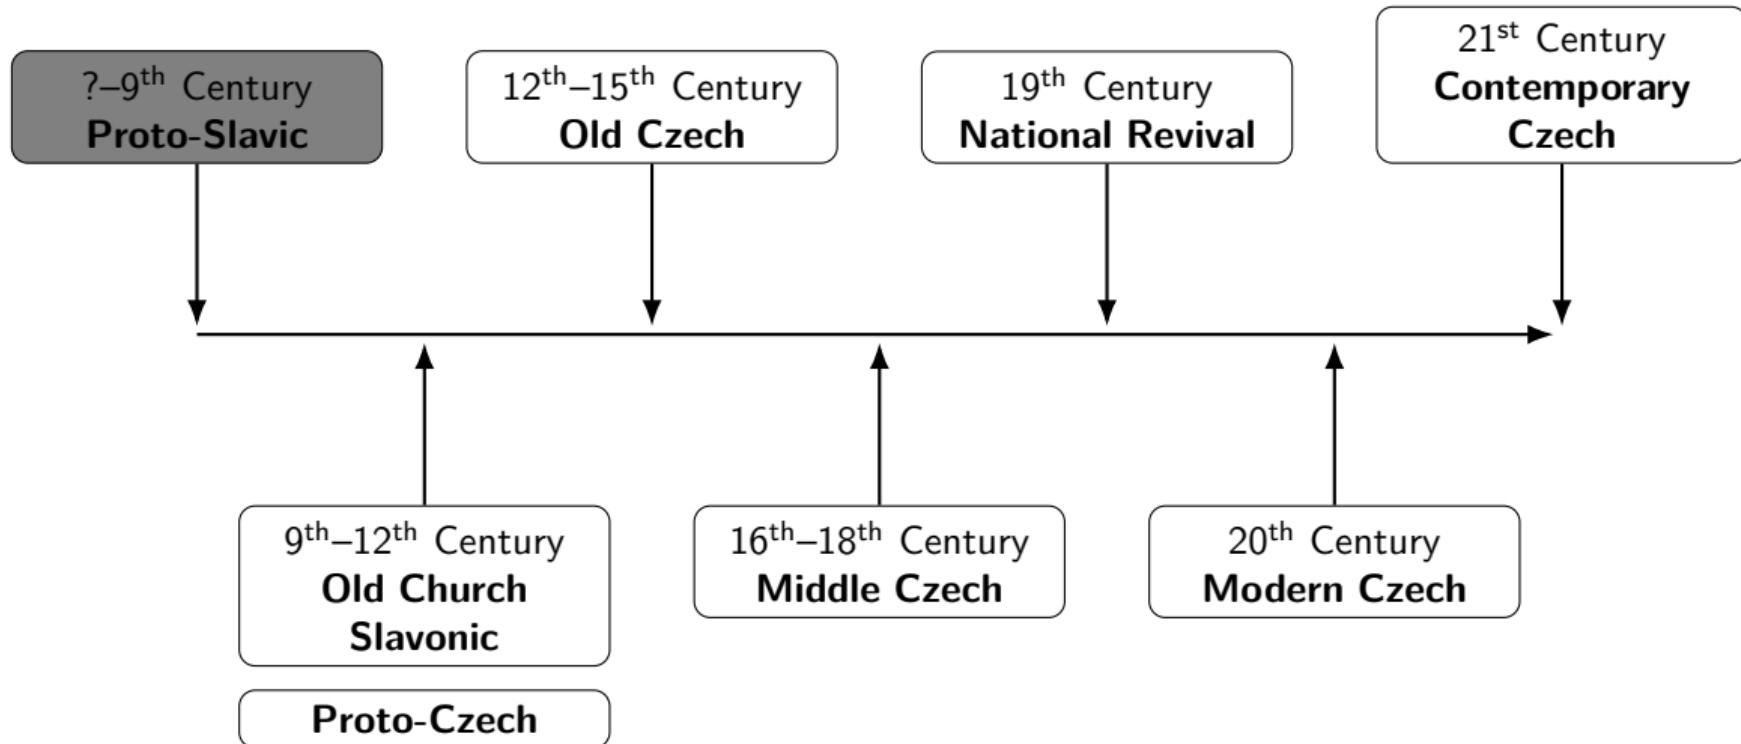
Goal

- Manual annotation of texts from all stages of Czech
- Universal Dependencies annotation style
- Only morphology (lemma, UPOS, features); no syntax
- Large enough to train a model ('etalon', ca. 100K words per period)
- UDPipe models will be freely available
 - Unfortunately, we are not allowed to make the data available for download
- Sources of data: ÚJČ, ČNK, NK
 - For some stages, no large corpus was available so far
 - Not even unannotated

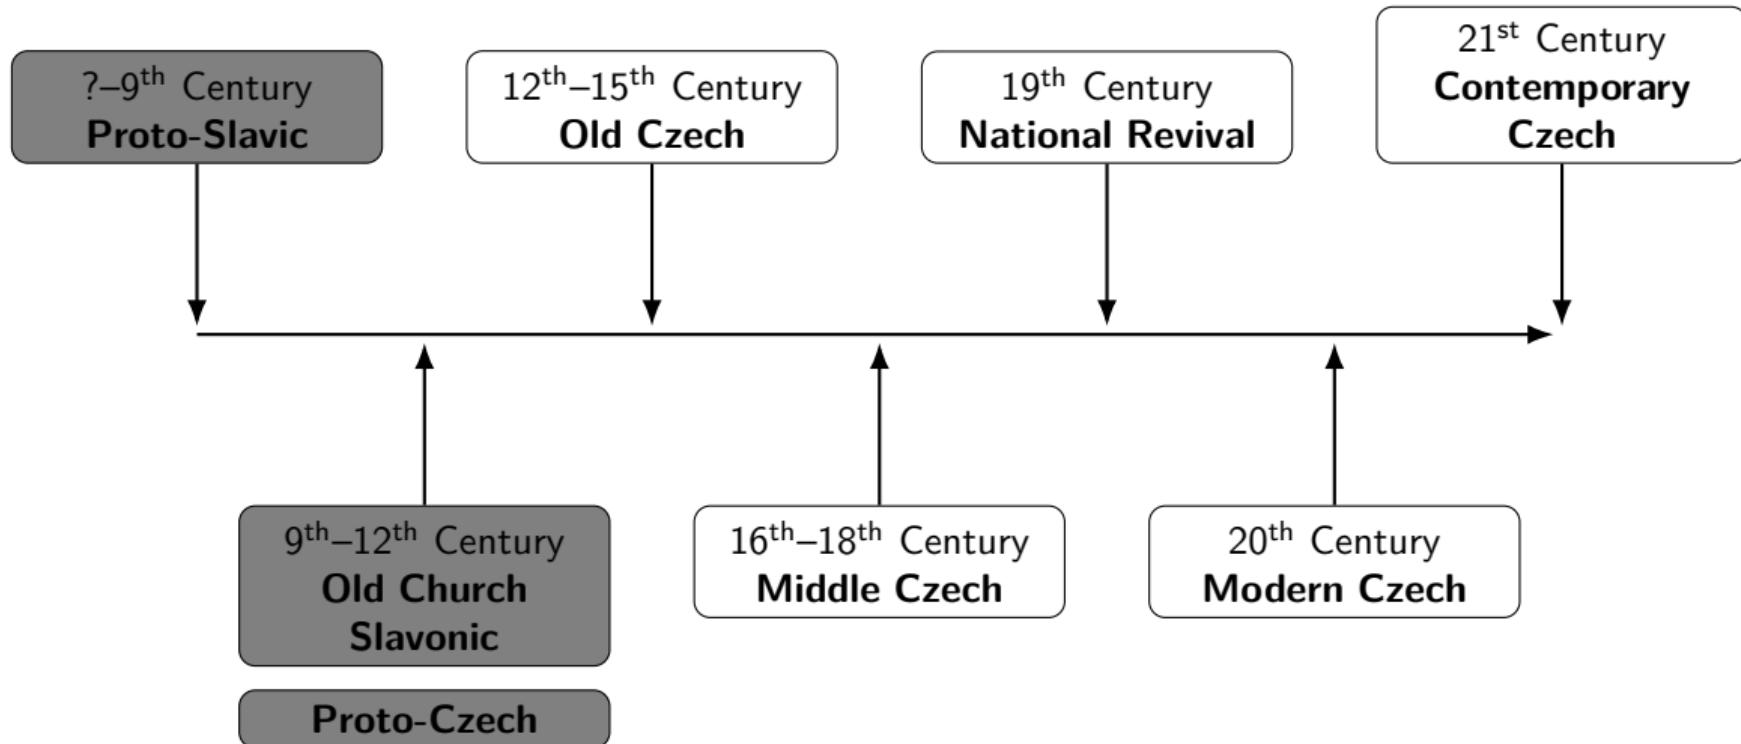
History of the Czech Language



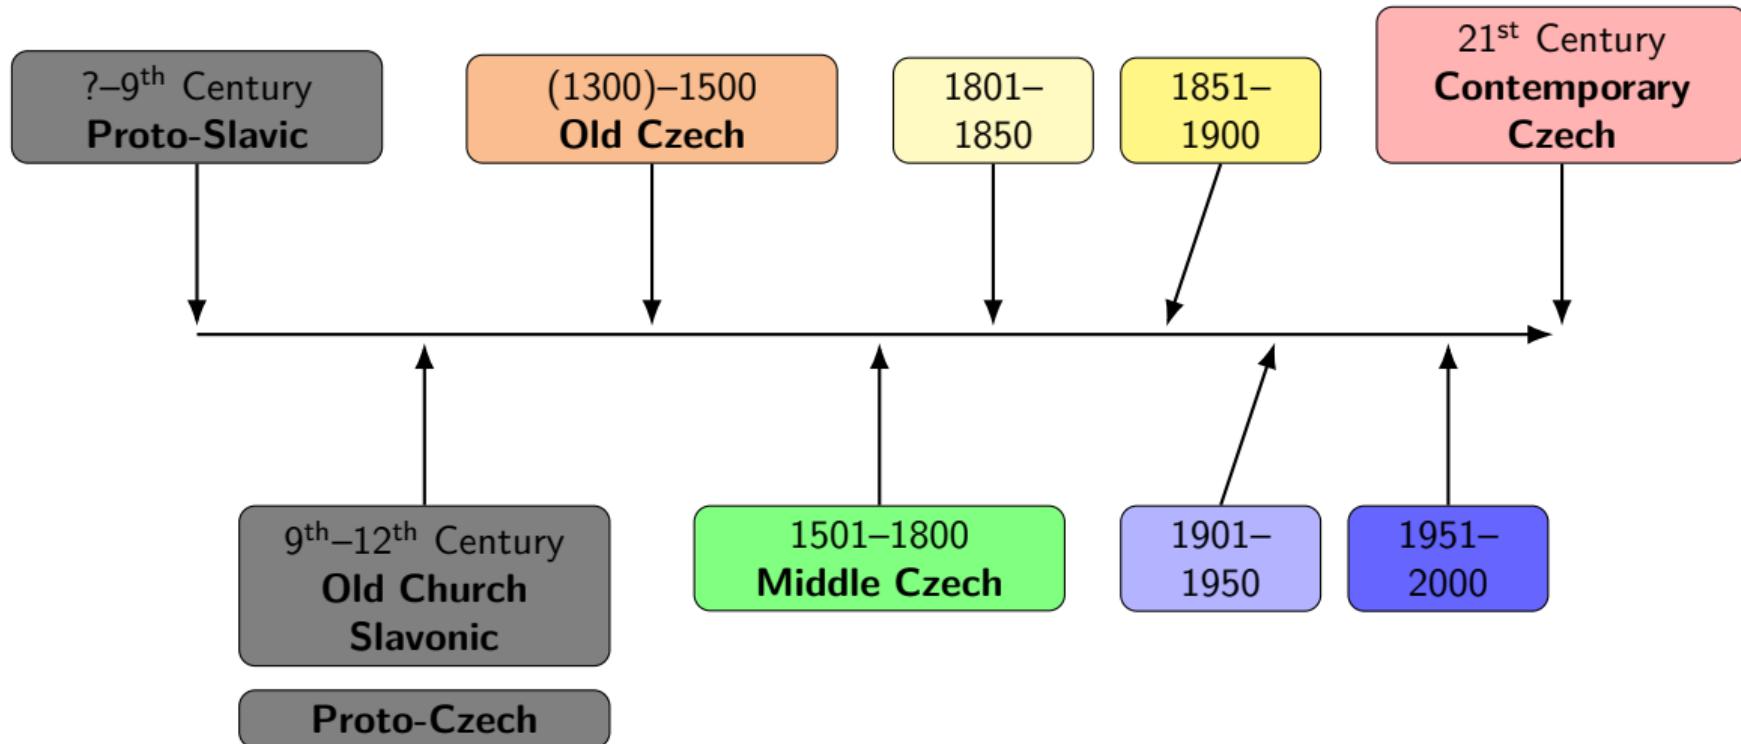
History of the Czech Language



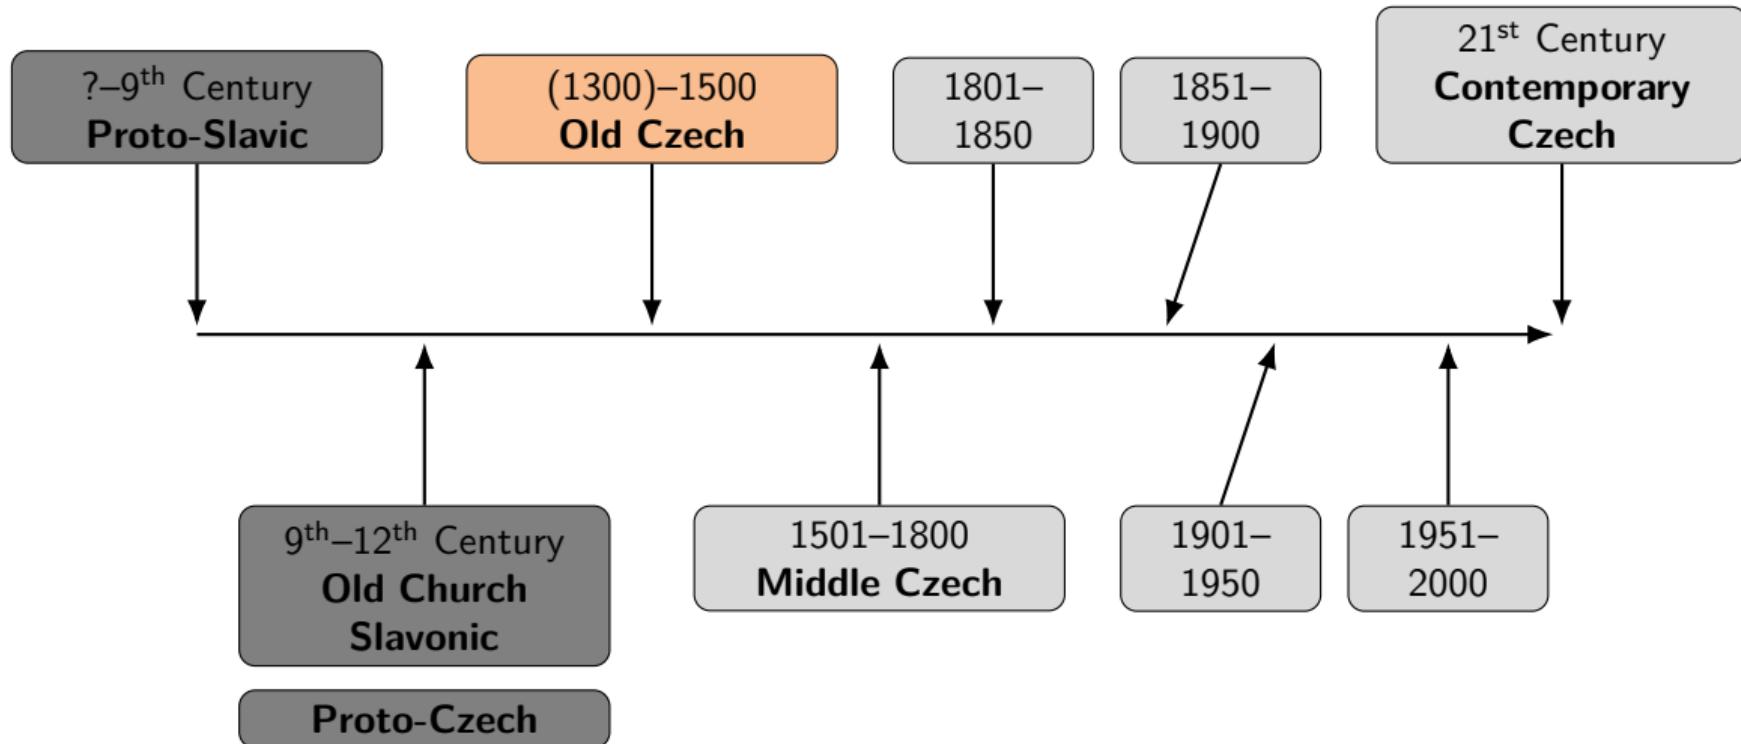
History of the Czech Language



History of the Czech Language



History of the Czech Language



Old Czech: Workflow

Old Czech Etalon

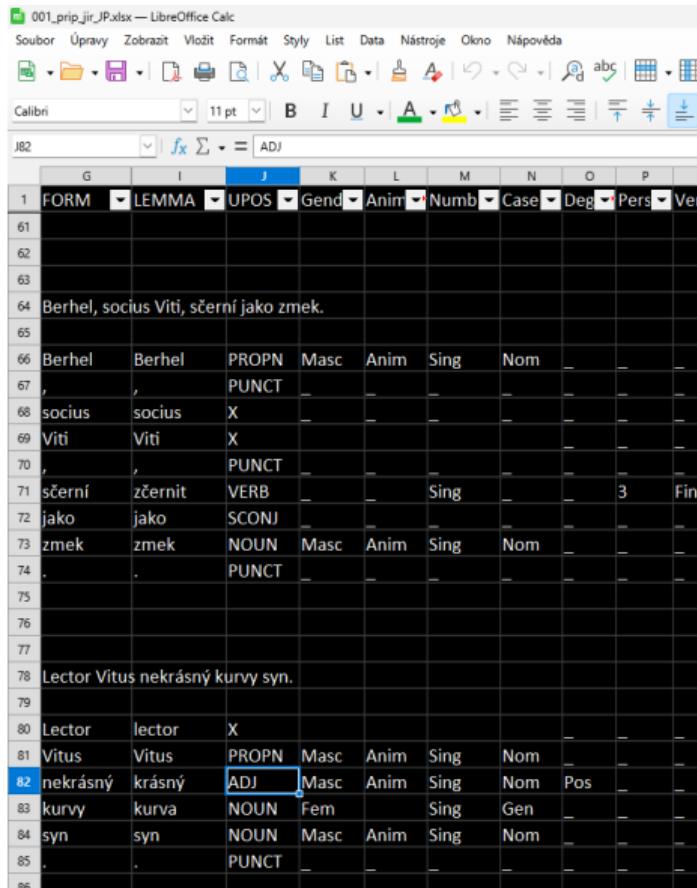
- 45 texts, oldest dated between 1290 and 1310
- Counts (may change during annotation):
 - 1294 sentences
 - 122,819 tokens
- Genres
 - Bible translations
 - psalms, prayers, sermons
 - epic
 - chronicles
 - regulations, law
 - medicine
 - proverbs, dream books
 - notes added to other texts

Workflow

- Preprocess by **UDPipe** trained on Modern Czech (PDT)
 - Plus rule-based script that fixes some frequent words (e.g. *řka* “saying”)
 - ⇒ sentence segmentation, lemmatization, UPOS, features, dependency relations

Workflow

- Preprocess by UDPipe trained on Modern Czech (PDT)
 - Plus rule-based script that fixes some frequent words (e.g. *řka* “saying”)
 - ⇒ sentence segmentation, lemmatization, UPOS, features, dependency relations
- Convert to TSV (table)
- Annotate in Excel



The screenshot shows a LibreOffice Calc spreadsheet titled "001_prep_jirJP.xlsx". The table has columns labeled G, I, J, K, L, M, N, O, P. Row 1 contains column headers: FORM, LEMMA, UPOS, Gend, Anim, Numb, Case, Deg, Pers, Ver. Rows 64 through 85 show individual words with their corresponding annotations. For example, "Berhel" is annotated as FORM, LEMMA: Berhel, UPOS: PROPN, Gend: Masc, Anim: Anim, Numb: Sing, Case: Nom. The word "zmek" is annotated as UPOS: PUNCT. The word "nekrásný" is highlighted in blue and annotated as UPOS: ADJ.

G	I	J	K	L	M	N	O	P		
1	FORM	LEMMA	UPOS	Gend	Anim	Numb	Case	Deg	Pers	Ver
61										
62										
63										
64	Berhel, socius Viti, sčerní jako zmek.									
65										
66	Berhel	Berhel	PROPN	Masc	Anim	Sing	Nom	_	_	
67	,	,	PUNCT	_	_	_	_	_	_	
68	socius	socius	X	_	_	_	_	_	_	
69	Viti	Viti	X	_	_	_	_	_	_	
70	,	,	PUNCT	_	_	_	_	_	_	
71	sčerní	zčernit	VERB	_	_	Sing	_	_	3	Fin
72	jako	jako	SCONJ	_	_	_	_	_	_	
73	zmek	zmek	NOUN	Masc	Anim	Sing	Nom	_	_	
74	.	.	PUNCT	_	_	_	_	_	_	
75										
76										
77										
78	Lector Vitus nekrásný kurvy syn.									
79										
80	Lector	lector	X							
81	Vitus	Vitus	PROPN	Masc	Anim	Sing	Nom	_	_	
82	nekrásný	krásný	ADJ	Masc	Anim	Sing	Nom	Pos	_	
83	kurvy	kurva	NOUN	Fem		Sing	Gen			
84	syn	syn	NOUN	Masc	Anim	Sing	Nom			
85	.	.	PUNCT	_	_	_	_			
86										

Workflow

- Preprocess by UDPipe trained on Modern Czech (PDT)
 - Plus rule-based script that fixes some frequent words (e.g. *řka* “saying”)
 - ⇒ sentence segmentation, lemmatization, UPOS, features, dependency relations
- Convert to TSV (table)
- Annotate in Excel
- Two annotators per file
- Convert to CoNLL-U, postprocess, **diff**
 - ⇒ one annotator resolves differences

The screenshot shows a Notepad2 window titled "003_ali_h_AM_JP.diff.txt - Notepad2". The window displays a list of differences found between two UDPIPE outputs, specifically comparing the AM (Annotator Model) and JP (Jaworski et al. 2016) annotations. The differences are listed in numbered lines, detailing specific tokens and their annotations across various linguistic features like UPOS, LEMMA, Gender, Number, Case, Animacy, Tense, Aspect, and Voice.

Line Number	Token	Feature	AM Annotation	JP Annotation
1	Line 37 (Sta)	Difference in UPOS	AM=AUX	JP=VERB
2	Line 50 (Lydu)	Difference in NameType	AM=Giv	JP=Geo
3	Line 56 (Tyrie)	Difference in LEMMA	AM=Tyří	JP=Tyrie
4	Line 63 (jich)	Difference in Gender	AM=_	JP=Masc
5	Line 63 (jich)	Difference in Animacy	AM=_	JP=Anim
6	Line 64 (čakajě)	Difference in Tense	AM=Past	JP=Pres
7	Line 65 (ležíše)	Difference in LEMMA	AM=ležíšet	JP=ležet
8	Line 67 (prěčakav)	Difference in Tense	AM=Pres	JP=Past
9	Line 67 (prěčakav)	Difference in Aspect	AM=Imp	JP=Perf
10	Line 68 (tu)	Difference in LEMMA	AM=ten	JP=tu
11	Line 68 (tu)	Difference in UPOS	AM=DET	JP=ADV
12	Line 68 (tu)	Difference in Gender	AM=Fem	JP=_
13	Line 68 (tu)	Difference in Number	AM=Sing	JP=_
14	Line 68 (tu)	Difference in Case	AM=Acc	JP=_
15	Line 77 (minu)	Difference in Variant	AM=Short	JP=Long
16	Line 85 (vojšče)	Difference in LEMMA	AM=vojště	JP=vojska
17	Line 85 (vojšče)	Difference in Gender	AM=Neut	JP=Fem
18	Line 85 (vojšče)	Difference in Case	AM=Acc	JP=Dat
19	Line 86 (odtad)	Difference in PronType	AM=Rel	JP=Dem
20	Line 94 (Divno)	Difference in LEMMA	AM=divno	JP=divný
21	Line 94 (Divno)	Difference in UPOS	AM=ADV	JP=ADJ
22	Line 94 (Divno)	Difference in Gender	AM=_	JP=Neut
23	Line 94 (Divno)	Difference in Number	AM=_	JP=Sing
24	Line 94 (Divno)	Difference in Case	AM=_	JP=Nom
25	Line 94 (Divno)	Difference in Variant	AM=_	JP=Short
26	Line 100 (sdieti)	Difference in LEMMA	AM=sdíti	JP=zdit
27	Line 102 (hna)	Difference in LEMMA	AM=hna	JP=hnát
28	Line 102 (hna)	Difference in Aspect	AM=Act	JP=Imp
29	Line 102 (hna)	Difference in Voice	AM=_	JP=Act
30	Line 105 (mil)	Difference in Number	AM=Sing	JP=Plur
31	Line 106 (třídícti)	Difference in Case	AM=Gen	JP=Acc
32	Line 122 (vzvěda)	Difference in LEMMA	AM=vzvěda	JP=zvědět
33	Line 129 (přijedá)	Difference in LEMMA	AM=přijedá	JP=přijet
34	Line 136 (tu)	Difference in LEMMA	AM=tady	JP=tu
35	Line 138 (Eufrates)	Difference in Animacy	AM=Anim	JP=Inan
36	Line 138 (Eufrates)	Difference in NameType	AM=Giv	JP=Gen

Workflow

- Preprocess by UDPipe trained on Modern Czech (PDT)
 - Plus rule-based script that fixes some frequent words (e.g. řka “saying”)
 - ⇒ sentence segmentation, lemmatization, UPOS, features, dependency relations
- Convert to TSV (table)
- Annotate in Excel
- Two annotators per file
- Convert to CoNLL-U, postprocess, diff
 - ⇒ one annotator resolves differences
- Official UD validation
- Additional consistency checks in [Udapi](#)
 - required & allowed features
- Return, fix, repeat...

```
# sent_id = 13_19_stol-003_axl_h-p1-s12
# text = Tak sě by vypravil hrdě, všu věcū silně i tvrdě.

Tak tak ADV _ PronType=Dem dep_
sě se PRON _ Case=Acc|PronType=Prs|Reflex=Yes obj_
by být AUX _ Aspect=Imp|Mood=Ind|Person=3|Polarity=Pos_
vypravil vypravit VERB _ Animacy=Anim|Aspect=Perf|Gender=
hrdě hrdě ADV _ Degree=Pos|Polarity=Pos dep SpaceAfter=
, , PUNCT _ punct_
všu všechn DET _ Case=Ins|Gender=Fem|Number=Sing|Pr=
věcū věc NOUN _ Case=Ins|Gender=Fem|Number=Sing de=
silně silně ADV _ Degree=Pos|Polarity=Pos dep =
i i CCONJ _ cc_
tvrdě tvrdě ADV _ Degree=Pos|Polarity=Pos conj Sp=
. . PUNCT _ punct_
```

```
# sent_id = 13_19_stol-003_axl_h-p1-s15
# text = S obú stranú toho voza, jež jich viera i jich hróza

S s ADP _ AdpType=Prep|Case=Gen case_
obú obě NUM _ Case=Gen|Gender=Fem|Number=Dual|NumFe=
stranú strana NOUN _ Case=Gen|Gender=Fem|Number=Dual|
toho ten DET _ Animacy=Inan|Case=Gen|Gender=Masc|
voza vůz NOUN _ Animacy=Inan|Case=Gen|Gender=Masc|!
, , PUNCT _ punct_
jež jenž PRON _ Case=Nom|Gender=Fem|Number=Sing|
jich on DET _ Case=Gen|Gender=Fem|Number=Sing|!
viera víra NOUN _ Case=Nom|Gender=Fem|Number=Sing|
i i CCONJ _ cc_
jich on DET _ Case=Gen|Gender=Fem|Number=Pos|
hróza hrúza NOUN _ Case=Nom|Gender=Fem|Number=Sing|
, , PUNCT _ punct_
jedieš být AUX _ Aspect=Imp|Mood=Ind|Number=Sing|Person=3|Polarity=Pos_
```

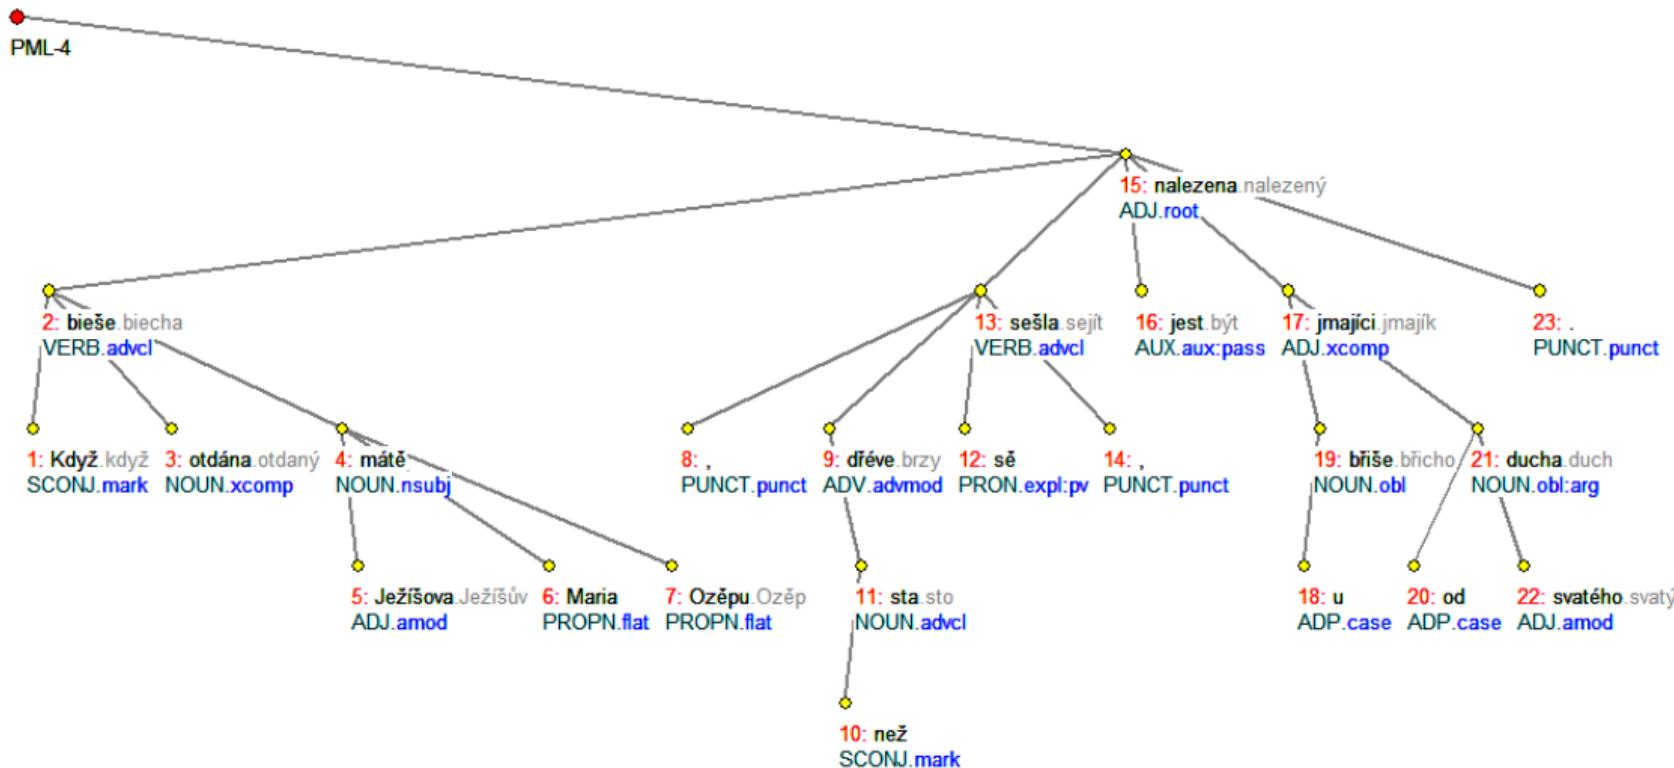
Czech UD Treebanks

- PDT (Prague Dependency Treebank)
 - Lidové noviny + Mladá Fronta + ČM Profit + Vesmír, 1993–1994
 - 87K sentences, 1.5M words
- CAC (Czech Academic Corpus / Korpus věcného stylu)
 - non-fiction, 1971–1985
 - 24K sentences, 493K words
- FicTree
 - fiction, from Czech National Corpus, 1991–2007
 - 12K sentences, 166K words
- CLTT (Czech Legal Text Treebank)
 - The Accounting Act (Zákon o účetnictví), 1991–2016
 - 1K sentences, 36K words
- PUD (Parallel Universal Dependencies)
 - online news + Wikipedia, translated from en/de/fr/it/es, around 2016
 - 1K sentences, 18K words
- Poetry
 - poetry, 19th century
 - 297 sentences, 6K words

PDT Model vs. Old Czech Data

- Genre, vocabulary: news vs. Bible
- Old vocabulary
- Orthography
 - Cleaned, transcribed, unified
 - But still not modern forms: *sě, viece*
- Grammar:
 - Dual number
 - Simple past (imperfect, aorist) (*bieše, vecě, jide*)
 - Converbs (přechodníky) (*řka, přistúpiv*)

Example Parse (UDPipe 2.0 on UD PDT 2.6)



Example Parse (UDPipe 2.0 on UD PDT 2.6)

ID	FORM	LEMMA	UPOS	XPOS	FEATS
1	Ale	ale	CCONJ	-	-
2	Kristovo	Kristúv	ADJ	-	Case=Nom Gender=Neut Gender[psor]=Masc NameType=Sur Number=Sing Poss=1
3	porozenie	porozenie	NOUN	-	Case=Nom Gender=Neut Number=Sing Polarity=Pos
4	tak	tak	ADV	-	PronType=Dem
5	bieše	biešat	VERB	-	Aspect=Imp Mood=Ind Number=Sing Person=3 Polarity=Pos Tense=Pres VerbForm=Fin
6	.	.	PUNCT	-	-

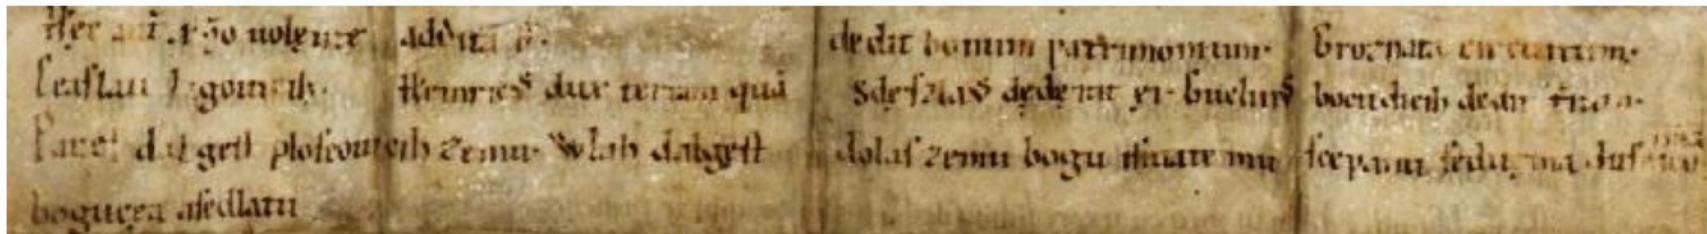
Bootstrapping

- 10 texts already annotated
 - 958 sentences, 20K words
- Retrain UDPipe
- Reparse the remaining files
- Hopefully better ⇒ less work for annotators
- Earlier experiments with Dresden Bible, Gospel of Matthew:

Model	Lemma	UPOS	Features
UDPipe 1.2 on PDT UD 2.5	70	77	55
UDPipe 1.2 on FicTree 2.10 + 1669 words of Matthew	78	85	65

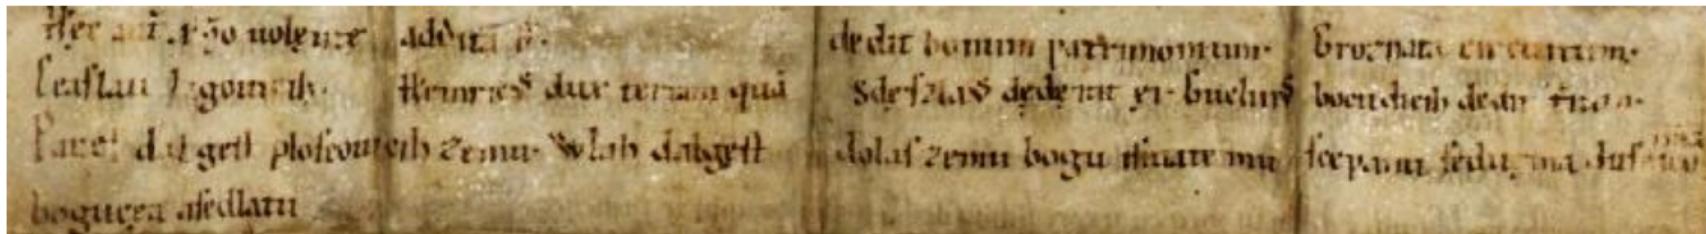
Old Czech: Interesting Issues

Modern Orthography vs. Modern Language



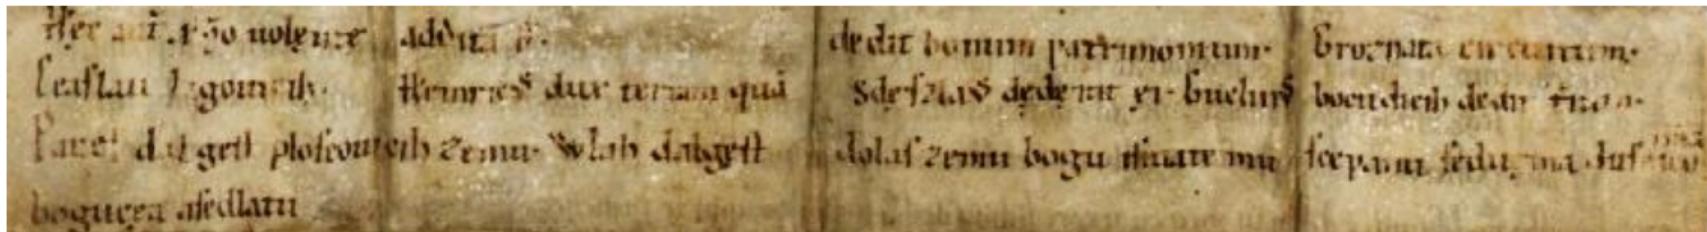
- Pavel dal gest ploskovicich zemu Vlach dal gest dolas zemu bogu i sviatemu Šcepanu seduema dusnicoma bogucea a sedlatu
- Pavel dal jest Ploskovicích zem'u, Vlach dal jest Dolas zem'u bogu i sv'atému Štěpánu se dvěma dušníkoma, Bogučeja a Sedlatu.
- Pavel dal v Ploskovicích zemi, Vlach dal v Dolanech zemi bohu i svatému Štěpánovi se dvěma dušníky, Bogučejem a Sedlatou.
- “Pavel gave land in Ploskovice, Vlach gave land in Dolas to God and St. Stephen with two villeins, Bogučej and Sedlata.”

Modern Orthography vs. Modern Language



- Pavel dal gest ploskovicih zemu Vlach dal gest dolas zemu bogu i sviatemu Šcepanu seduema dušn'ikoma bogucea a sedlatu
- Pavel dal jest Ploskovicích zem'u, Vlach dal jest Dolas zem'u bogu i sv'atému Ščepánu se dvěma dušníkoma, Bogučeja a Sedlatu.
- Pavel dal v Ploskovicích zemi, Vlach dal v Dolanech zemi bohu i svatému Štěpánovi se dvěma dušníky, Bogučejem a Sedlatou.
- “Pavel gave land in Ploskovice, Vlach gave land in Dolas to God and St. Stephen with two villeins, Bogučej and Sedlata.”

Modern Orthography vs. Modern Language



- Pavel dal *gest* ploskovicích zemu Vlach dal *gest* dolas zemu bogu i sv'atému Ščepánu se dvěma dušníkoma, Bogučeja a Sedlatu.
- Pavel dal *jest* Ploskovicích zem'u, Vlach dal *jest* Dolas zem'u bogu i sv'atému Ščepánu se dvěma dušníkoma, Bogučeja a Sedlatu.
- Pavel dal *v* Ploskovicích zemi, Vlach dal *v* Dolanech zemi bohu i svatému Štěpánovi se dvěma dušníky, Bogučejem a Sedlatou.
- “Pavel gave land in Ploskovice, Vlach gave land in Dolas to God and St. Stephen with two villeins, Bogučej and Sedlata.”

Tokenization

- UD concept of **multiword tokens**
 - one orthographic word → multiple morphosyntactic words
- Modern Czech examples:
 - *kdybychom* “if we would” = *když*/**SCONJ** + *bychom*/**AUX**
 - *udělalas* “you.Fem.Sing did” = *udělala*/**VERB** + *jsi*/**AUX**
 - *ses* = *jsi*/**AUX** + *se*/**PRON**

Multiword Tokens in Old Czech

Preposition + accusative pronoun:

<i>nač</i>	=	<i>na</i>	<i>co</i>	PronType=Rel
<i>naň</i>	=	<i>na</i>	<i>něj</i>	PronType=Prs
<i>naňž</i>	=	<i>na</i>	<i>nějž</i>	PronType=Rel
<i>oč</i>	=	<i>o</i>	<i>co</i>	PronType=Rel
<i>oň</i>	=	<i>o</i>	<i>něj</i>	PronType=Prs
<i>oňž</i>	=	<i>o</i>	<i>nějž</i>	PronType=Rel
...				
<i>předeň</i>	=	<i>před</i>	<i>něj</i>	PronType=Prs
<i>skirzěňž</i>	=	<i>skirzě</i>	<i>nějž</i>	PronType=Rel
...				
<i>zaňž</i>	=	<i>za</i>	<i>nějž</i>	PronType=Rel

The Particle-Clitic *-t'*

Function hard to nail down: discourse connective, emphasis, sometimes even personal pronoun *ti* "you.Dat".

mnohémuť = *mnohému* *t'*

Examples:

- *pakt', tedyť, ješčet', ktožť, mnohémuť, vzpomenúť, neopustíť...*

Except for lexicalized cases:

- *at', (byť), nebt', nebot', necht', (tot'), (vždyť)*

Emphatic -ž

Narrower and less fuzzy function than -ť – analyzed differently!

- No splitting, kept as one word
- Lemmatized without -ž
- New feature: **Emph=Yes**
- But not for lexicalized cases

Examples:

- *dřevniehož, rcěmež, budž, mějž, přezříž...*

Except for lexicalized cases:

- *aniž, což, jakož, jehož, kdož, když, kterýž, nikdož, protož, takž, všelicož, ...*

Tokenization

- Opposite situation: Old spelling with space.
 - *kdo koli* “anybody”
 - prepositional phrases vs. compound adverbs

Lemmatization

- Not only picking base form in the paradigm...
- ... but also normalization among alternatives...
- ... even after modernizing orthography!
 - *Křtitel* “Baptist”
 - *Křstitel*
 - *Krstitel*

Lemmatization

- Not only picking base form in the paradigm...
- ... but also normalization among alternatives...
- ... even after modernizing orthography!
 - *Křtitel* “Baptist”
 - *Křstitel*
 - *Krstitel*
- Modern lemma vs. old lemma:
 - forms = *otsúdí* / *otsúdie* “she / they will condemn”
 - lemma candidates = *odsoudit*, *odsouditi*, *odsúditi*, *odsúziti*, *otsoudici*, *otsoudit*, *otsouditi*, *otsúdici*, *otsúdit*, *otsúditi*, *vodsoudit*, *vodsouditi*, *vodsúditi*, *votsoudici*, *votsoudit*, *votsouditi*, *votsouditi*, *votsúdici*, *votsúdit*, *votsúditi*, ...
 - (modern) lemma = *odsoudit*

Modern Lemma Not Always Easy to Identify

- *jmě* “name” → *jméno*
- *ješutenstvie* “conceit” → *ješitenství*
- *podvstati* → *podvstat?*
- *uvrci* “cast” → *uvrhnout* ... change of inflection class
- *přijeti* “accept” → *přjmout*
- *cizý* “foreign” → *cizí*
- Homonyms with similar meaning:
 - *břich* vs. *břicho* “belly”
 - *obecný* “common” vs. *obecní* “of community”

Negation

Modern Czech data (PDT) until UD 2.14:

- **VERB** productive: *dělat* “to do” → *nedělat* “not to do”
 - Lemma = affirmative form, features: **Polarity=Neg**

Negation

Modern Czech data (PDT) until UD 2.14:

- **VERB** productive: *dělat* “to do” → *nedělat* “not to do”
 - Lemma = affirmative form, features: **Polarity=Neg**
- **ADJ** productive (but competing with antonyms):
hezký “pretty” → *nehezký* “unpretty, ugly”
 - Lemma = affirmative form, features: **Polarity=Neg**

Negation

Modern Czech data (PDT) until UD 2.14:

- **VERB** productive: *dělat* “to do” → *nedělat* “not to do”
 - Lemma = affirmative form, features: **Polarity=Neg**
- **ADJ** productive (but competing with antonyms):
hezký “pretty” → *nehezký* “unpretty, ugly”
 - Lemma = affirmative form, features: **Polarity=Neg**
- **ADV, DET** somewhat productive:
nedávno “recently”, *nezávisle* “independently”; *neméně* “no less”

Negation

Modern Czech data (PDT) until UD 2.14:

- **VERB** productive: *dělat* “to do” → *nedělat* “not to do”
 - Lemma = affirmative form, features: **Polarity=Neg**
- **ADJ** productive (but competing with antonyms):
hezký “pretty” → *nehezký* “unpretty, ugly”
 - Lemma = affirmative form, features: **Polarity=Neg**
- **ADV, DET** somewhat productive:
nedávno “recently”, *nezávisle* “independently”; *neméně* “no less”
- **NOUN** theoretically all are negatable (even **PROPN!**) but it is rare
 - Meaning is often shifted
 - Annotation not completely consistent
 - **Inflection:** *nezávislost* “independence”, *neschopnost* “incompetence”, *nemožnost* “impossibility”, *nedodržení* “nonobservance”, *neznalost* “unawareness”
 - **Derivation:** *nebezpečí* “danger”, *nedostatek* “shortage”, *nezaměstnanost* “unemployment”, *nemovitost* “real estate”, *nesmysl* “nonsense”, *neštěstí* “misfortune, accident”

Negation

Old Czech data and Modern Czech data (PDT) **since UD 2.15**:

- **NOUN** does not have **Polarity**, lemma with *ne-* ⇒ negation is derivation
- **All** non-pronominal **ADV** have **Polarity** (*nevelmi* “not much” – this can be also quantifier, i.e., **DET**)
- Some pronominal **ADV** have it, too (*nevždy* “not always”)

Morphological Features

Simple Past Tense: Imperfect

- Old: *Ale Kristovo porozenie tak biešē.*
 - VERB VerbForm=Fin Mood=Ind Tense=Imp Aspect=Imp Voice=Act Number=Sing Person=3 Polarity=Pos
- Modern: *S narozením Ježiše Krista to bylo takto:*
 - VERB VerbForm=Part Tense=Past Aspect=Imp Voice=Act Number=Sing Gender=Neut Polarity=Pos
- English: “Now the birth of Jesus Christ took place in this way.”

Morphological Features

Simple Past Tense: Imperfect

- Old: *Ale Kristovo porozenie tak bieše.*
 - VERB VerbForm=Fin Mood=Ind Tense=Imp Aspect=Imp Voice=Act Number=Sing Person=3 Polarity=Pos
- Modern: *S narozením Ježíše Krista to bylo takto:*
 - VERB VerbForm=Part Tense=Past Aspect=Imp Voice=Act Number=Sing Gender=Neut Polarity=Pos
- English: “Now the birth of Jesus Christ took place in this way.”

Simple Past Tense: Aorist

- Old: *Tehdy oni pověděchu jemu:*
 - VERB VerbForm=Fin Mood=Ind Tense=Past Aspect=Perf Voice=Act Number=Plur Person=3 Polarity=Pos
Variant=Long
- Modern: *Oni mu řekli:*
 - VERB VerbForm=Part Tense=Past Aspect=Perf Voice=Act Number=Plur Gender=Masc Animacy=Anim Polarity=Pos
- English: “They told him,”

Conditional vs. Aorist of “to be”

- | | | Sing | Dual | Plur | |
|--|-----------|-------------|----------------|---------------|-----------------------|
| • Aorist of <i>být</i> “be” | 1 | <i>bych</i> | <i>bychově</i> | <i>bychom</i> | *) and other variants |
| | 2 | <i>by</i> | <i>bysta</i> | <i>byste</i> | |
| | 3 | <i>by</i> | <i>bysta</i> | <i>bychu</i> | |
| • Modern Conditional auxiliary | | Sing | Plur | | |
| | 1 | <i>bych</i> | <i>bychom</i> | | |
| | 2 | <i>bys</i> | <i>byste</i> | | |
| 3 | <i>by</i> | <i>by</i> | | | |
| • Even modern <i>by</i> can be 2 nd person in <i>by ses</i> | | | | | |
| • In Old Czech, aorist servers as conditional auxiliary... | | | | | |
| • ... but <i>by</i> is used in various persons and numbers | | | | | |
| • Aorist usages must be distinguished from conditional | | | | | |

Morphological Features

Dual Number

- Old: ... *uzřě dva braty, ... že biešta rybáře.*
 - **NOUN** Gender=Masc Animacy=Anim Number=Dual Case=Nom
- Modern: ... *uviděl dva braty, ... byli totiž rybáři.*
 - **NOUN** Gender=Masc Animacy=Anim Number=Plur Case=Nom
- English: "... he saw two brothers, ... for they were fishermen."

Morphological Features

Dual Number

- Old: ... *uzřě dva braty*, ... *že biešta rybáře*.
 - **NOUN** Gender=Masc Animacy=Anim Number=Dual Case=Nom
- Modern: ... *uviděl dva braty*, ... *byli totiž rybáři*.
 - **NOUN** Gender=Masc Animacy=Anim Number=Plur Case=Nom
- English: "... he saw two brothers, ... for they were fishermen."

Animacy

- Not significant grammatically as in modern Czech
- But tentatively annotated anyway, to be consistent with modern Czech data

Morphological Features

Converbs (= Gerunds = Transgressives)

- Old: *Tehdy ona ihned **ostavše** sieti, jidesta po něm.*
 - VERB VerbForm=Conv Tense=Past Aspect=Perf Voice=Act Number=Dual Polarity=Pos
- Modern: *Oni hned **opustili** síť a následovali ho.*
 - VERB VerbForm=Part Tense=Past Aspect=Perf Voice=Act Number=Plur Gender=Masc Animacy=Anim Polarity=Pos
- English: “Immediately they left their nets and followed him.”

Morphological Features

Converbs (= Gerunds = Transgressives)

- Old: *Tehdy ona ihned **ostavše** sieti, jidesta po něm.*
 - **VERB** VerbForm=Conv Tense=Past Aspect=Perf Voice=Act Number=Dual Polarity=Pos
- Modern: *Oni hned **opustili** sítě a následovali ho.*
 - **VERB** VerbForm=Part Tense=Past Aspect=Perf Voice=Act Number=Plur Gender=Masc Animacy=Anim Polarity=Pos
- English: “Immediately they left their nets and followed him.”

Accusative Converbs?

- Old: ... *někteří ... neuzřie syna člověčežho, **přijdúce** v svém království.*
 - **VERB** VerbForm=Conv Tense=Pres Aspect=Perf Voice=Act Number=Sing Gender=Masc Animacy=Anim Polarity=Pos **Case=Acc**
- Modern: ... *někteří ... nespatří Syna člověka **přicházejícího** ve své královské moci.*
 - **ADJ** VerbForm=Part Tense=Pres Aspect=Imp Voice=Act Number=Sing Gender=Masc Animacy=Anim Polarity=Pos **Case=Acc**
- English: “... some ... (will not) see the Son of Man coming in his kingdom.”
- Decision: No **Case** feature with conversbs.

Morphological Features

Supine vs. Infinitive (???)

- Old: *Nalezeny sú oslice, jichžtos byl šel hledat.*
 - VERB VerbForm=Sup Aspect=Imp Polarity=Pos
- Modern: *Oslice, které jsi šel hledat, se našly.*
 - VERB VerbForm=Inf Aspect=Imp Polarity=Pos
- English: “The donkeys that you went to seek are found.”
- UD knows supine in Modern Slovenian.
- But what criteria would we use in Czech?

Summary

- 100K UD-style etalons to train UDPipe for each period
- Current work:
 - The ÚJČ team + DZ: Old Czech
 - The ÚČNK team + BŠ: 19th century
 - The NK team: preparing data from 20th century
- Modern lemma to facilitate searching
- Morphological features for extinct phenomena
- Tokenization: Multi-word tokens