
OZNAČEVANJE UDELEŽENSKIH VLOG V UČNEM KORPUSU ZA SLOVENŠČINO

SIMON KREK, POLONA GANTAR, KAJA DOBROVOLJC IN IZA ŠKRJANEC

Jezikovne tehnologije in digitalna humanistika, Ljubljana, 29. 9 – 1.10. 2016

ZGODOVINA

- XLike - Cross-lingual Knowledge Extraction; IJS (2012-2014)
- Clarin Slovenija - Slovenska raziskovalna infrastruktura za jezikovne vire in tehnologije (2015)
- CJVT – Center za jezikovne vire in tehnologije (2016)
- Bilateralni projekt med Slovenijo in Hrvaško (2015-2017)

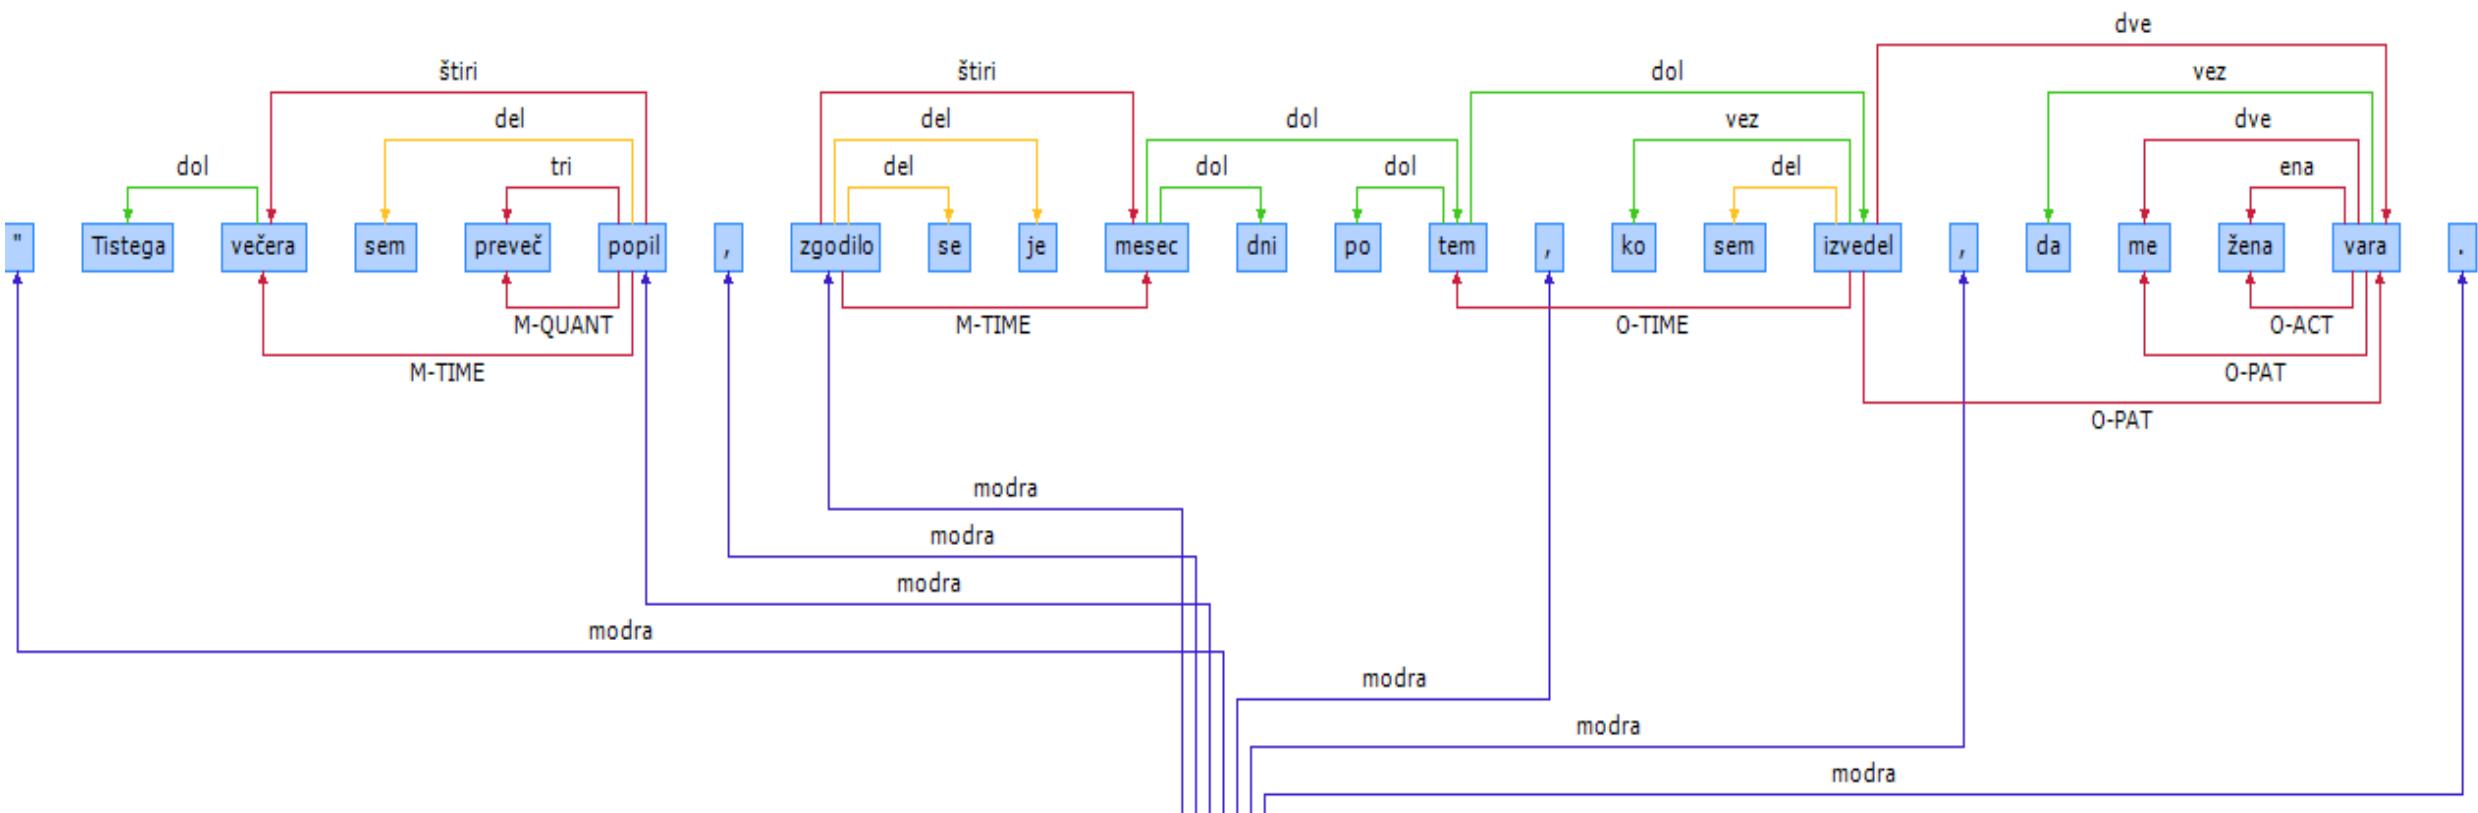
- Sodelujoči : Simon Krek, Kaja Dobrovoljc, Sara Može, Polona Gantar, Iza Škrjanec Dafne Marko in ...
- Dostopnost: Clarin.si; CC

CILJI IN METODE

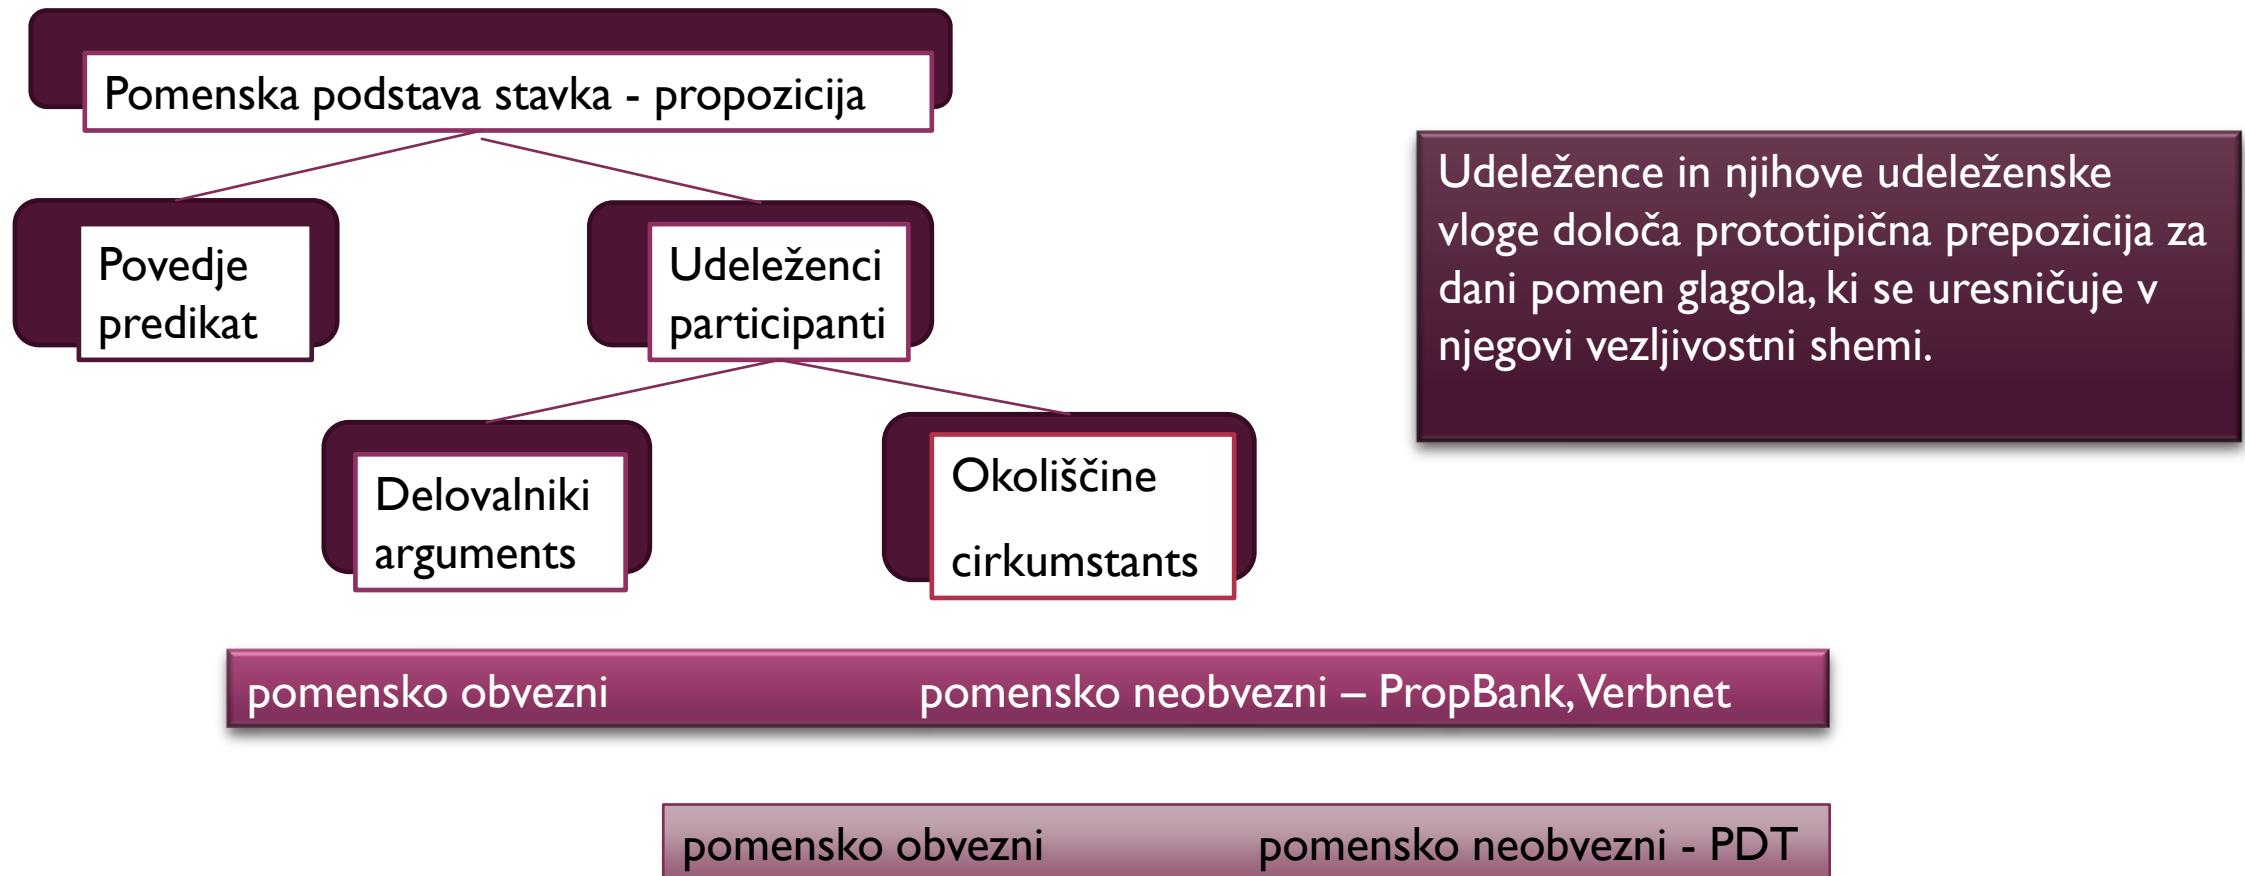
- Izhajati iz jezikovnih specifik slovenščine in upoštevati medjezikovno kompatibilnost oznak in mednarodne standarde (→ UD)
- Zagotoviti optimalen nabor kategorij
- Upoštevati odsotnost leksikona glagolske vezljivosti
- Metode semantičnega označevanja in semantične kategorije
 - Prague Dependency Treebank (Mikulová et al., 2006)
 - PropBank (Palmer et al., 2005)
 - Verbnet (Kipper et al., 2006)
 - AnCora (Taulé et al., 2011)
 - SoNaR (Schuurman et al., 2010)
 - nabor oznak za hrvaščino (Filko et al., 2012)
 - češki valenčni leksikon Vallex in FrameNet (Backer et al., 1998)

KORPUS IN OZNAČEVALNIK

- SSJ500k
- SentenceMarkup System (Dobrovoljc et al., 2012)



TEORETIČNA IZHODIŠČA



NABOR UDELEŽENSKIH VLOG - DELOVALNIKI

Oznaka	Opis	Primer	
ACT	aktant, vršilec	delajoči udeleženci, povzročitelji ali nosilci dejanja	<u>Oče</u> ACT dela.
PAT	prizadeto	prizadeti predmet dejanja	Kuhajo <u>kosilo</u> PAT
REC	prejemnik	prejemnik, posredni udeleženec dejanja; nedelovalniški udeleženec, ki mu je dejanje v škodo ali v prid	Prijatelju REC sem poslal darilo.
ORIG	izvor	izhodišče, izvor/vir/povod dejanja	Plašč je dobil od <u>očeta</u> ORIG
RESLT	učinek	učinek, rezultat, cilj dejanja	Imenovali so ga za <u>predsednika</u> RESLT

NABOR UDELEŽENSKIH VLOG – OKOLIŠCINE: ČAS IN PROSTOR

Oznaka	Opis			Primer
ČAS	TIME	čas	konkretni trenutek ali interval dejanja; kdaj	Med <u>počitnicami</u> _{TIME} ni niti enkrat posijalo sonce.
	DUR	trajanje	trajanje stanja, dejanja koliko časa	Prišel je za en <u>mesec</u> _{DUR}
	FREQ	pogostnost	frekvenca dejanja; kako pogosto, kolikokrat	Vsak <u>dan</u> _{FREQ} se mučimo s tem.
PROSTOR	LOC	kraj	konkretna lokacija, kraj, mesto dejanja; kje	V <u>bližini vasi</u> _{LOC} stoji kozolec.
	SOURCE	začetna lokacija	začetna točka v prostoru; od kod	S <u>stropa</u> _{SOURCE} odpada omet.
	GOAL	končna lokacija	končna točka v prostoru; kam	Prišel je <u>domov</u> _{GOAL}

Oznaka	Opis			Primer
VZROČNOST	AIM	namen	namen dejanja; čemu, s kakšnim namenom	Telovadi, da bi <u>shujšala</u> AIM
	CAUSE	vzrok	vzrok dejanja; zakaj	Umrl je zaradi <u>srčne kapi</u> CAUSE
	CONTR	protivnost	nepričakovana posledičnost dejanja; kljub čemu	<u>Medtem ko se plače nižajo</u> , CONTR cene rastejo
	COND	pogojnost	pogoj za obstoj dejanja ali dogodka	<u>Če neha deževati</u> COND gremo na kavo.
	REG	ozir	glede na, primerjava	Preiskava je potekala <u>v skladu z zakonom</u> , no-REG
NAČIN	ACMP	spremstvo	predmet, oseba ali dogodek, ki spremlja dejanje ali druge udeležence	Mama je s <u>sinom</u> ACMP odšla v cirkus.
	RESTR	omejitev	izjema, omejitev	Vsi so bili tam razen <u>tebe</u> RESTR
	MANN	način	načinovna lastnost dejanja,	Dela <u>prepočasi</u> MANN
	MEANS	sredstvo	sredstvo ali orodje za izvedbo dejanja	Piše s <u>peresom</u> MEANS
KOLIČINA	QUANT	količina	količina, razlika	Cena goriva se je podražila za <u>3 cente</u> QUANT

NABOR UDELEŽENSKIH VLOG – GLAGOLSKE ZVEZE

Oznaka	Opis	Primer
GLAGOLSKIE ZVEZE	MWPRED	zveze z nedoločniki Dati vedeti _{MWPRED}
	MODAL	zveze biti + modalnega prislova/pridevnika je treba, je mogoče
	PHRAS	pomensko neprozorne zveze Iti na živce _{PHRAS}

biti + **pridevnik** = RESLT: stvar je zapletena _{RESLT}

Imeti avto – PAT

biti + **samostalnik** = PAT: območje medenice je središče telesa _{PAT}

Imeti krompir/smolo – PHRAS

biti + **prislov** = MANN: da vam bo toplo _{MANN}

Imeti prednost/možnost/predavanje - LVC

KONKURENČNA POMENSKOSKLADENJSKA RAZMERJA - I

- **Med delovalniki**

- ACT – PAT; ACT – REC; PAT – REC; PAT – RESLT; PAT – ORIG

- **Med delovalniki in okoliščinami**

- ACT – LOC ...
- PAT – MEANS ...
- REC – AIM ...

- **Med okoliščinami**

- TIME – LOC; TIME – MANN ...
- LOC – RESLT; LOC – MANN ...
- CAUSE – LOC; CAUSE – TIME; CAUSE – MANN

Pripis udeleženske vloge mora ostati nespremenjen v različnih skladenjskih realizacijah udeleženca.

AKTANT – PRIZADETO

AKTIV

dogodki (ACT) so se odvijali

* Kdo (ACT) odvija dogodke (PAT)

PASIV

Pozitivna diskriminacija (PAT) se označuje kot privilegij

Kdo (ACT) označuje pozitivno diskriminacijo (PAT) kot privilegij

Kdo (ACT) malce zaplete stvar (PAT) → Stvar (PAT) je malce zapletena.

→ Stvar (PAT) se je malce zapletla

PROSTORSKO IZRAŽENI DELOVALNIKI

- ACT – LOC
 - v bolnišnici (LOC → ACT) bodo uvedli
 - pri Fujifilmu (LOC → ACT) so objavili
 - na centru (LOC → ACT) se bojo lotili
 - so sporočili iz združenja (LOC → ACT)
 - v Avstrijskem časopisu (LOC → ACT) objavljujo
 - v osnovni šoli v Bistrici (LOC → ACT) pripravljajo
- REC – LOC
 - je zganila v meni (LOC → REC)
 - boste v sebi (LOC → REC) začutile življenje
 - bodo povzročile nevšečnosti na televiziji (LOC → REC)

ČASOVNOPROSTORSKA IN VZROČNA POMENSKOSKLADENJSKA RAZMERJA

- TIME – LOC = **EVENT**
 - sploh ni padel y vojni (TIME – LOC → EVENT)
 - na enem od sestankov (TIME – LOC → EVENT) jim je dejala
- TIME – CAUSE
 - dekle je ob vzvratni vožnji (TIME → CAUSE) začelo vpiti
 - ob zadnjih zapletih (TIME → CAUSE) se je županja odločila

V PRIHODNJE

- Na podlagi nabora udeleženskih vlog in meril označiti še preostali del polovice skladenjsko označenega korpusa SSJ500k (4,500 stavkov)
- Prehod v Universal Dependencies
- Obligatornost udeleženskih vlog

- Dodati nov nivo za označevanje večbesednih enot (MWE)



Zahvalujem se vam_[REC] za pozornost_[PAT]!