

# **Priprema usporedivih korpusa za usporedbu**

Ivana Lalli Paćelat  
Sveučilište Jurja Dobrile u Puli

# Uvod

- ❖ važnost i sustavno planiranje izrade skupa oznaka u skladu sa standardima
- ❖ preduvjet usporedivosti među korpusima na unutarjezičnoj i na međujezičnoj razini
- Što kada se takvi skupovi oznaka ne koriste?

## Priprema korpusa za istraživanje:

Analiza zakonodavnopravnoga stila hrvatskog i talijanskog jezika: unutarjezična, međujezična i prijevodna perspektiva

Za **analizu registra** neophodno je imati (Biber 1995):

- 1) **komparativni pristup,**
- 2) **kvantitativnu analizu** (*distribucija vrsta riječi: omjer imenica i glagola, distribucija glag. oblika, distribucija kateg. lica, distribucija modalnih gl., distribucija vrsta zamjenica, prijedloga, veznika i dr., omjeri pojavnica i različnica, leksičke gustoće, leksičkoga bogatstva;*)
- 3) **reprezentativni uzorak.**


# Korpusi

➤ šest različitih korpusa odnosno četiri vrste korpusa:

1. referentni korpusi: HNK v3.0 i CORIS,
2. dvojezični usporedivi korpus: potkorpus HNK v3.0, NN1990-2013 i potkorpus CORIS-a, PRGAMM,
3. jednojezični usporedivi korpusi: NN1990-2013 i hrAcquis; PRGAMM i itAcquis,
4. usporedni korpus: hrAcquis i itAcquis.\*

(Rossini Favretti et al. 2002, Tadić 2009, Tadić et al. 2012, Tamburini et al. 2009)

# Komparativni pristup



# Provjera usporedivosti među korpusima

## ➤ Korpusi u sličnim istraživanjima !!!

(Cortelazzo 2013, Neumann, 2013; Teich, 2003; Venturi 2011, Xiao 2010 i dr.)

## ➤ Provjera usporedivosti među korpusima

## ➤ HNK & CORIS / NN1990–2013 & PRGAMM / hrAcquis & itAcquis

➤ raspon, opseg, struktura

➤ označavanje ?

➤ POS/ MSD označavanje

# Analiza skupova oznaka

## □ Skupovi oznaka:

1) HNKv3.0, NN1990–2013 i hrAcquis



**MULTEXT\*-East (v4.0)** specifikacija (Tadić 1998, Erjavec 2004)

2) CORIS i PRGAMM



!!!

**EAGLES-like tagset for Italian** (Tamburini 2000, Monachini 1995)

3) itAcquis → **Freeling tagset** (Prokopidis i suradnici 2011)

## □ Razlika u razini označavanja!!!

\**MULTEXT preporuka razrađena u suradnji s EAGLES inicijativom iz 1996.*

# Potreba za uskladjivanjem oznaka

CORIS

Oznaka	Opis
V_AVERE	svi oblici (pomoćnoga) glagola <i>avere</i> (hr. <i>imat</i> )
V_ESSERE	svi oblici (pomoćnoga) glagola <i>essere</i> (hr. <i>biti</i> )
V_MOD	svi oblici glagola <i>potere, dovere, volere</i> (hr. <i>moći, morati, htjeti</i> )
V_PP	glagolski pridjevi <sup>317</sup>
V_GVRB	općeniti <sup>318</sup> glagolski oblici
V_CLIT	združeni <sup>319</sup> glagolski oblici (npr. <i>andarci, dimmelo</i> ; hr. <i>ići tamo, reci mi to</i> )

C	Vrijednost	C	Vrijednost	C	Vrijednost	C	Vrijednost
I	Vrsta	2	Oblik	3	Vrijeme	4	Lice
V	glavni glagol	i	indikativ	p	prezent	1	1.lice
VA	pomoćni glagol	m	imperativ	i	imperfekt	2	2.lice
VM	modalni glagol	d	kondicional	s	perfekt	3	3.lice
		c	konjuktiv	f	futur		
		f	infinitiv				
		g	glagolski prilog ( <i>gerundio</i> )				
		p	glagolski pridjev ( <i>participio</i> )				

HNKv3.0,  
NN1990-2013,  
hrAcquis

# Usklađivanje oznaka I

- svođenje na (samo) zajedničke POS/MSD oznake
  - odabir : MULTEXT-East (v4.0) specifikacija (Tadić 1998, Erjavec 2004)

IT-ACQUIS	CORIS	HNK	Odabrana oznaka za ovaj rad i objašnjenje	
V	V	V	V	glagol
VA	V_ESSERE	Va	Va	pomoćni glagol
	V_AVERE	Vc		
VM	V_MOD	Vm	Vm	glagolski oblik suznačnoga ili samoznačnoga glagola
V	V_GVRB			
	V_CLIT			
Vp	V_PP			

složenije  
pretrage s  
RI!!

Tablica 1: Prijedlog zajedničkih oznaka za glagole

# Usklađivanje oznaka II

Razlike u poimanju i postojanju gramatičkih kategorija !

itACQUIS			CORIS	HNK	Odabrana oznaka za ovaj rad i objašnjenje		
S			N	N	N	imenica	
Ss	Sp	Sn	NN	Nc	Nc	opća imenica	
SP			NN_P	Np	Np	vlastita imenica	
SWs	SWp	SWn					
B			ADV	R	R	prilog	
BN				Qr			
				Qz			

Tablica 2: Prijedlog zajedničkih oznaka za imenice i priloge

- status čestica !!!
- rješenje: uključivanje dijela pojavnica s oznakom čestica koje se u talijanskome jeziku smatraju prilozima


# Usklađivanje oznaka III

Razlike u poimanju i postojanju gramatičkih kategorija

itACQUIS			CORIS	HNK	Odabrana oznaka za ovaj rad i objašnjenje			
<b>A</b>			ADJ	A	<b>A</b>	pridjev		
As	Ap	An	ADJ	Af	Af	opisni pridjev		
			ADJ_NUM	Aø	Aø	brojevni pridjev <sup>321</sup>		
APs	APP	APn	ADJ_POS PRON_POS	Ps Px	Psx	posvojna zamjenica/pridjev (it)/povratno-posvojna zamjenica (hr)		
P			PRON	P	P	zamjenica		
PE			PRON_PER	Pp	Ppx	osobna zamjenica/povratna zamjenica (hr)		
PC				Px				
PD			PRON_DIM	Pd	Pd	pokazna zamjenica/pridjev (it)		
DD			ADJ_DIM					
PI			PRON_IND	Pi	Piqr	neodređena zamjenica/pridjev (it)/upitna zamjenica/pridjev (it)/odnosna zamjenica/pridjev (it)		
DI			ADJ_IND					
PQ			PRONIES	Pq				
DQ			ADJIES					
PR	DR		PRON_REL	Pr				


Tablica 3: Prijedlog zajedničkih oznaka za zamjenice i pridjeve

# Primjer postupka usklađivanja I



Slika 1. Mogućnosti kontrastivne analize posvojnih zamjenica odnosno pridjeva u postojećim korpusima

# Primjer postupka usklađivanja II



Slika 2. : Prijedlog usklađivanja oznaka povratne i povratno-posvojne zamjenice

# Primjer postupka usklađivanja III

doc#150641 zaslijepljeni , Hrvat . Zašto to morate trpjeti ? Zašto dopuštate da ova /Pd-fsn--n-a.. žena /Ncfpg vrijeda vašu inteligenciju ? Valjda zato što volite p  
doc#158823 danas se kreće samo uz pomoć štaka , a zadnjih godinu i pol ova /Pd-fsn--n-a.. žena /Ncfpg sve svoje vrijeme provodi na liječenju u toplicama  
doc#179899 vušićki nadrljiječnik osim nje prevario i jednu osobu iz Buzeta . Ova /Pd-fsn--n-a.. žena /Ncfpg policiji je ispričala da se s Gladovićem našla u Istri  
doc#190437 zaboravljena , najpoznatija američka »antiratna mama « Cindy Sheehan . Ova /Pd-fsn--n-a.. žena /Ncfpg koja je izgubila sina jedinca u Iraku svojevremeno

MISCVolumi: , il terrorismo - e accompagna <questa donna> coraggiosa alla sua fine , ci  
MON2001\_04: guito nel 1993 , ha permesso a <questa donna> di essere sottoposta a una fe  
MON2005\_07: Come può Suze essere amica di <questa donna> ? Com ' è possibile ? All ' i  
MON2005\_07: l pianeta . La tragica fine di <questa donna> , la prima a dirigere un Paes

doc#132184 nikada neće biti pronađeno . Blair , međutim , tvrdi " kako nema nikakve /Pi-fsg--n-a.. sumnje /Ncfsg " da ono postoji i da će  
doc#132405 razgovora nema . Svaka čast koprivničkim navijačima , ali nema nikakve /Pi-fsg--n-a.. sumnje /Ncfsg da će naše rukometnički  
doc#133462 , s još kakvim pravom , da će to biti Hrvatska . </p><p> Nema nikakve /Pi-fsg--n-a.. sumnje /Ncfsg da su Hrvati favoriti u d  
doc#133507 da širi poruku pomirenja , tolerancije i dijaloga - u to nema nikakve /Pi-fsg--n-a.. sumnje /Ncfsg . </p><p> Sve ove poru  
MON2001\_04: n per l ' abito più brutto . E <nessun dubbio> sulla vincitrice per la peggia  
MON2001\_04: Alfio . Sei tu , non ho avuto <nessun dubbio> . Se queste tue capacità sono  
MON2005\_07: religione » - non può esserci <nessun dubbio> . L ' Europa può essere definita  
MON2005\_07: poseremo . Su questo non c ' è <nessun dubbio> . C ' è qualche dubbio ? " "N

# Usklađivanje oznaka IV

Razlike u poimanju i postojanju gramatičkih kategorija !

itACQUIS	CORIS	HNK	Odabrana oznaka za ovaj rad i pojašnjenje	
E	PREP	Sp	Sp	prijedlog
EA	PREP_A			
Cc	CONJ_C	Ccs	Cc	veznik nezavisnosloženih rečenica ili konjunktor
		Ccc		
Cs	CONJ_S	Css	Cs	veznik zavisnosloženih rečenica ili subjunktor
		Csc		
NOs	NOn	ADJ_NUM	Ao M	brojevi i brojevni pridjevi
NUM	C_NUM			

Tablica 4: Prijedlog zajedničkih oznaka za prijedloge i brojeve

- različiti status brojeva !!!
- rješenje: odvajanje brojevnih pridj. od ostalih pridj. i njihovo uključivanje pod zajedničku oznaku brojeva

# Normalizirani korpus

## ➤ Problem člana

(Ljubičić 2000, Karlić 2013 i dr. + provjera na usporednome korpusu)

Primjeri neiskazivanja vrijednosti člana u hrvatskome jeziku:

„....u vezi s kvalitativnim **Ø** značajkama riže...“ (jrc31999R0691)

„....per quanto riguarda **le** caratteristiche qualitative del riso...“ (jrc31999R0691)

„....za potvrđivanje usklađenosti **Ø** određenog proizvoda ili **Ø** obitelji proizvoda...“ (jrc31999R0691)

„....se per **un** dato prodotto o **un** gruppo di prodotti determinati...“ (jrc31999D0089)

Primjeri iskazivanja vrijednosti člana u hrvatskome jeziku:

„....budući da je zato poželjno odrediti **onaj** koncept proizvoda ili obitelji...“ (jrc31999D0089)  
„...è opportuno definire **il** concetto di prodotto o di gruppo di prodotti...“ (jrc31999D0089)

„....«proizvođač» je **svaka** osoba čijom aktivnošću nastaje otpad...“ (jrc32006L0012)  
„...«produttore»: **la** persona la cui attività ha prodotto rifiuti...“ (jrc32006L0012)

# Normalizirani korpus

- Normalizirana veličina korpusa kao zaključak
  - promatranje distribucije unutar zajedničkih dijelova korpusa
    - samo oznake koje su zajedničke i relevantne za istraživanje

**Isključeni:**

- ✓ članovi i čestice
- ✓ kratice, pokrate, simboli, interpunkcijski znakovi
- ✓ užvici

**Normalizirani korpus uključuje:**


imenice (N), glagole (V), pridjeve (A), veznike (C), priloge (R), zamjenice (P), prijedloge (Sp) i brojeve (M).

# Opseg izvornih vs. normaliziranih korpusa


Korpus	Apsolutni broj pojavnica u izvornome korpusu	Apsolutni broj pojavnica u normaliz. korpusu	Omjer broja pojavnica u izvornome i normaliz. korpusu
HNK	216 812 148	177 216 713	0,8173
NN <sub>1990_2013</sub>	92 363 788	70 852 385	0,7671
hrAcquis	11 209 795	8 784 240	0,7836
CORIS	130 294 347	98 300 670	0,7544
PRGAMM	9 575 784	7 325 921	0,7650
itAcquis	16 955 483	12 464 404	0,7351

# Normalizirani vs. nenormalizirani korpusi

Grafikon 1. Usporedba distribucije vrste riječi u RefHR



Grafikon 2. Usporedba distribucije vrste riječi u RefIT



**Distribucija vrsta riječi u HNK-u i CORIS-u**

# Zaključak

- važnost i sustavno planiranje izrade skupa oznaka u skladu sa standardima   
preduvjet usporedivosti među korpusima na unutarjezičnoj i međujezičnoj razini
- hrvatski +, talijanski -
- neusklađenost oznaka, tj. postojanje različitih skupova POS i MSD oznaka za isti jezik
  - onemogućuje unutarjezičnu analizu korpusa i ograničava primjenu

# Zaključak

- neizbjegno promišljanje i usklađivanje oznaka s obzirom na razlike u poimanju i postojanju gramatičkih kategorija u pojedinim jezicima
- normalizacija korpusa → rješenje za određene analize
  - ➡ usporedivost i pouzdanost rezultata
- usporedba i usklađivanje MSD ili POS oznaka - kontrastivna analiza
- budući korpori → univerzalni skupovi
  - ➡ takva usklađivanja neće biti potrebna.