



ACT

Computer Processing of Written Cultural Heritage Sources

*Jiří Bubník, Jiří Čelák, Vojtěch Janota,
Alexandr Kára, Václav Novák,
Kiril Ribarov, Tomáš Vondra*



We will focus on:

Lexical and corpus processing of written cultural sources

We place the written cultural sources in an electronic contextual (e-context) field with the following connecting elements:

- source image along with language based contextual structure of the word mass present in the sources
- connections (inner and outer links) among various types of written cultural sources within wider cultural environment.



We aim at:

Development of technologies and tools
for
large-scale activities
aimed towards
multi-aspectual presentation
of
written cultural heritage
in a
highly distributed manner



Our approach is:

→ **Experimental**

development of various tools
and their testing and modification
based on user-specialist input.

↓
Collecting experience

from past models and experiments

*Developed as individual work and recently also as student project at the
Center for Computational Linguistics, Charles University.
INFORUM 2004*



Corpus Processing

- Developed for contemporary languages
- Existence of various corpus managers


but

None of them covers specialties present in processing of old sources (dead languages).

**We need special approaches,
but whenever possible,
we prefer the use existent modules.**



The input



Gn 1, 26–32; Gn 2, 1–3; Pr 2, 1–9

18

ι πο πόβηστα Ϝ;;:ι δα Ωθιδοετ 7 ρ—βαμι μο
ρ7σκ—μι;;:ι πτιχομι νεβην—μι Ψκοτ—;;:
ι α/σε3 ζεμε3;;:ι γαδ—α/σμι πρ↓ φι—κοβ
] 4 πο ζεμψ;=&ι στωρι β7 =λεκα πο Ωφραζου θι
Ωι8;;:μ4εαι εεν4 στωρι λ7 εστ7;;:=* 1 βγοσθιψ
3 β7 γλ2;;:ρωσιτα σ2 1 πλωδιτα σ2 1 στλνιτα ζε
μ2 1 Ωθιδαιτα ε3;;:ι Ωθιδαιτα ρ—βαμι μο
ρ7σκ—μι;;:ι πτιχομι νεβεον7μι ;;;:ι α/σμιΨ
σκοτ© 1 α/σε3 ζεμε3;;:ι α/σμι γαδ—πρδφι—
κοεμψ;=& 1 ρθ87 σ δω7 αμ7 α/σκ4 τρ↓ α/σ
μενψ4;;:δ3] 43 αμ2;;εε εστ7 αρ7η8 ζεμ2;;:
1 α/σδκο δρδω εεε ειμα α/σ αεβδ πλωδ7;;:δμενε
μενψα αμ7 β4δ4τ7 α/σ 5δ7;;:#) 1 α/σμ7 / α
ρεμ7 ζεμ7αμ7μ7;;:ι α/σμ7 πτιχομ7 νεβε
σν—μ7;;:ι α/σκ8 πρδφι©κοβ] αμω σ2 πο ζεμψ;
εε ειματ7 α/σ αεβδ δ[4 ειωτν43;;:ι α/σκ4 τρδ
α/σ ζλα=ν43 α/σ 5δ7;;:ι βα—τακο #! 1 αδ5 β7 α/σ δ→ε
στωρι;;:ι σ δοφρα / 5λο;;:#= 1 βα—τωι βα—ουρρο δν7;;:δ;;:
! σ/φη[ει νεβο 1 ζεμ2 1 α/σλ 5ποτ4 ε' ;;;:ι σ/φη[1
β7 α/σ δν7;;:δ5λα αμδ δ→ε ε στωρψ;ι πο=ι α/σ δη7 δ;;:
1 δι1 ζανε α/σ ν7 πο=ψ;.. α/ση7 δ5λ7 ααη7 3εε να=2
τ7 β7 τωρψ1;;:;;:πψο;;:γλα;;:λ;;:λ;;:πρι ζρψι ασλ—
[Ψμ2 1 ι βε μοι προσκατψ; 1 δοκολ5 1 ι ζαβ4δε1 1;;:
;;:.. πρι δη7;;:τ εν1 ε;:::δ;;:

Cανε α/σ ε πριεμ7 γλανι ε ζαπωδι μ3 σ/κρ—ε[Ψ ε%
α/σ αεβδ;;:πασιλου[αετ7 πρδμ4δροσι αυηρ τωε;;:
1 πρι λωει φχε τωε τροζ8μ7;;:πρι λω7[1 εε νοκα
ζανε δηνα ταεμωυ;;:# α/σ ε πρδμ4δροσ7 πρι ζαε
[1;;:ι ραζαυμ7 δαα γλα τωι;;:Ε 1 α/σ ε α/σ—έ ε
[1 εγο;;:πασιλου[αρζαυμ5ε[1 βολζ7 γν2;;:ι ρα
ζαυμ7 Ωφρ2] ε[1;;:5κο γ7 δαετ7 πρδμ4δροσ7;;:
.. λιχα εγο ραζ8μ7 1 πραδα;;:&1] 4διτ7 1 στρα



ι πο πάρστα ϖ;;ι δα Ωβλαδαετ 7 ρ—βαμι μο
 β7ακ—μι;;ι πτιχαμι νεβλυ—μι Ψακοτ—;;;
 ι ωσε3 ζεμε3;;ι γαδ—ωτμι πρ↓ α—κα3
] 4 πο ζεμψ;=&ι σταρι β7 =λγκα πο Ωβραζου βι
 Ωι8;;μ4εαι εεν4 σταρι λ7 εσ7;;=* 1 βγγοσλαψ
 3 β7 γλ2;;ρασιτα α2 1 πλαδιτα α2 1 σαλ7νιτα ζε
 μ2 1 Ωβλαδατα ε3;;ι Ωβλαδατα ρ—βαμι μο
 β7ακ—μι;;ι πτιχαμι νεβεσο7μι;;ι ωτμψ
 ακοτ© 1 ωσε3 ζεμε3;;ι ωτμι γαδ—πρδμ—
 καεμψ;≡ 1 ρ@β7 σε δαη7 αμ7 ωτκ4 τρ↓ α4 τ
 μενψ4;;τ3] 43 τμ2;;εε εσ7 φ7η8 ζεμ2;;
 ι ωτκο δρτω εε εμα ω σεβ πλαδ7;;τμενε τ
 μενψα αμ7 β4δ4τ7 σ7 5δ7;;#) 1 ωτμ7 / τ
 ρεμ7 ζεμ7ακ©μ7;;ι ωτμ7 πτιχαμ7 νεβε
 σνμ7;;ι ωτκ8 πρδμ©κα3) ομαυ α2 πο ζεμψ;
 εε εμα7 ω σεβ δ[4 ειταν43;;ι ωτκ4 τρδ
 α4 ζλα=v43 ω 5δ7;;ι βα—τακο #! 1 αδ5 β7 ωτκ ↓εε
 σταρι;;ι σε δοβρα / 5λο;:#= 1 βα—αη1 βα—αυτρο δv7;;z;;
 ! σ7φ7[ει νεβο 1 ζεμ2 1 ωτλ λ5ποτ4 ε' ;;;= 1 σ7φ7[1
 β7 ω δv7;;z;;δ5λα στω δ↓εε σταρψ;ι πο=ι ω δv7 δ;;;
 # 1 δτι ζανε ω v7 πο=ψ;.. ωτηη7 δ5λ7 ααηη7 3εε νο=2
 τ7 β7 ταρψ;ι;::;πψο;::γλα;::λ;::παζρψι αα—
 [Ψμ2 γι βε μοι προσταψ;] δοκολ5 γι ζαβ4δε[1;;;
 ::; ∴ πρτ@7;;=τ εν1 ε;::;λ;::;

Cγε α] ε πρι εμ7 γλανι ε ζαποκδι μ3 σ7κρ—ε[Ψ ≈%
 ω σεβ;::;πασιλο[αετ7 πρδμ4δροσι αυτρ τωε;;;
 1 πρι λωι1 φχε τωε ταρξ8μ7;;πρι λω7[1 εε νοκα
 ζανι ε δγου τασεμου;;# α] ε πρ•μ4δροσ7 πρι ζαπε
 [1;;ι ραζαυμ7 δασ γλα τωι;;Ξ 1 α] ε ωζ—ε
 [1 εγο;;%τογδα ραζαυμ5ε[1 βολζν7 γγ2;;ι ρα
 ζαμ7 Ωβρ2] ε[1;;ι 5κο γ7 δαετ7 πρδμ4δροσ7;;
 ∴ λιχα εγο ραζ8μ7 1 πρασδα;::&ι] 4δι τ7 1 στρα

Original forms:

!

,!*,

Gn, ≈1 πο πάρστα ϖ;;ι δα Ωβλαδαετ 7 ρ—βαμι μο?
 β7ακ—μι;;ι πτιχαμι νεβλυ—μι Ψακοτ—;;;
 ι ωσε3 ζεμε3;;ι γαδ—ωτμι πρ↓ α—κα3?
] 4 πο ζεμψ;=&ι σταρι β7 =λγκα πο Ωβραζου βι
 Ωι8;;μ4εαι εεν4 σταρι λ7 εσ7;;=* 1 βγγοσλαψ?
 3 β7 γλ2;;ρασιτα α2 1 πλαδιτα α2 1 σαλ7νιτα ζε?
 μ2 1 Ωβλαδατα ε3;;ι Ωβλαδατα ρ—βαμι μο?
 β7ακ—μι;;ι πτιχαμι νεβεσο7μι;;ι ωτμψ
 ακοτ© 1 ωσε3 ζεμε3;;ι ωτμι γαδ—πρδμ—?
 καεμψ;≡ 1 ρ@β7 σε δαη7 αμ7 ωτκ4 τρ↓ α4 τ

.....



,!*,

ΕGn, ≈ 1 πο πόβ7στω με; ;ι δα Ωβλαδαι7 ρ-βαμι μο?

ρ7ακ-μι; ;ι πτιχαμι νεβον-μι Ψακοτ-;;;

ι ω/α3 ζεμε3; ;ι γαδ-ω/τμι πρ↓φι-κα3?

] 4 πο ζεμψ; ;&1 στωρι β7 =λάκα πο Ωβρος ου βι

Ωμ8; ;μ4εα 1 εεν4 στωρι λ7 εστ7; ;≈ 1 βιγοσλωτη?

3 β7 γλ2; ;ρωστιτα α2 1 πλοδιτα α2 1 σπλ7νιτα ζε?

μ2 1 Ωβλαδαιτα ε3; ;ι Ωβλαδαιτα ρ-βαμι μο?

ρ7ακ-μι; ;ι πτιχαμι νεβεσον/μι; ;ι ω/τμψ

ακοτ© 1 ω/α3 ζεμε3; ;ι ω/τμι γαδ-πρδφι-?

καεμψ; ;&1 ρ⊗β7 σε δαη7 ωμ7 ω/τκ4 τρ↓τι τ

18r1,3:

πο<δο>β7στωιφο

18r4,5: β<ογ>7

18r5,7:

βλ<α>γοσλωτι?3

Original forms:



18r10.2. Δε<=ε>
Rendered forms:



Multiple meanings, Multiple Understanding, Multiple.....

ι||εγοεε||τιδι[ι||πλοδα||σε||σ7τωρι||τ7||μν5

(and the fruit you see created in me),

the string σ7τωρι||τ7||μν5

2 variants!


could also be divided as σ7τωριτ7||μν5

(where σ7τωριτ7 is the past participle - active mood of *create*)

both are grammatically correct




...multiple...multiple...multiple...





ACT Structure



v-1,3:1,1.0 | Display ... | Cpx1

ДА БѢДЕТЪ НА ТЕРЗДИ ПО СРѢДѢ ВОДЗИ И ДА БѢ/ДЕТЪ
 ДА С БѢДЕТЪ С НА С ТЕРЗДИ С ПО С СРѢДѢ С ВОДЗИ С И С ДА С БѢ/ДЕТЪ С
 РАЗЛЖУЂАШИ МЕЖДОУ ВОДОА С БО(ДО)/А
 РАЗЛЖУЂАШИ С МЕЖДОУ С ВОДОА С С С БО(ДО)/А С
 И Б҃ССТВ> ТАКО И СТВОРН Б^ОГРЗ ТЕРЗДЗ И РАЗ(ЛЖ)/УН
 И С Б҃ССТВ> С ТАКО С И С СТВОРН С Б^ОГРЗ С ТЕРЗДЗ С И С РАЗ(ЛЖ)/УН С
 Б^ОГРЗ МЕЖДОУ ВОДОА ЂКОЖЕ БѢ НАДЗ (ТЕРЗ)/ДНА
 Б^ОГРЗ С МЕЖДОУ С ВОДОА С ЂКОЖЕ С БѢ С НАДЗ С (ТЕРЗ)/ДНА С
 МЕЖДОУ ВОДОА ЂЖЕ БѢ ПОДЗ ТЕРЗ/ДНА
 МЕЖДОУ С ВОДОА С ЂЖЕ С БѢ С ПОДЗ С ТЕРЗ/ДНА С
 И Б҃ССТВ> ТАКО НАРЕУКЕ Б^ОГРЗ ТЕРЗДЗ НЕБО
 И С Б҃ССТВ> С ТАКО С НАРЕУКЕ С Б^ОГРЗ С ТЕРЗДЗ С НЕБО С
 И БНДѢ Б^ОГРЗ ЂКО ДОБРО И Б҃ССТВ> КЕУКЕРЗ И Б҃ССТВ> ОУТРО
 И С БНДѢ С Б^ОГРЗ С ЂКО С ДОБРО С И С Б҃ССТВ> С КЕУКЕРЗ С И С Б҃ССТВ> С ОУТРО С

Original forms - Ctrl F1 Rendered forms - Ctrl F2 Keywords - Ctrl F3 Morphology - Ctrl F4 Translation - Ctrl F5

Rendered form Rendered form full

на на

[Previous](#) [Next](#) [Next ambiguous](#)

All variants

Keyword	Tag	Add
		Delete

Current morphological variant

Part of speech: - Keyword: - [Edit assistant settings](#)

Morphological tag



Inputs and Outputs

- **Input:** RTF, XML, TXT
- **Output** (for any subset of documents) HTML, XML, RTF, TXT:
 - various search outputs
 - complete index (index verborum)
 - concordance index
 - word frequencies
 - bigrams
 - retrograde indexes
 - etc...



Documents in ACT

Catalogue: language, sorting, morphology

Text: *Document₁* *Document_n*

Pictures: *Document₁* *Document_n*

Pictures: *Card File₁* *Card File_{15 000 000}*

Location+ Oform --> guess context



A single card

ГЫБНЯТИ *ірф.*

Ap Slěpc. 2 Cor 4,3.
Fol. 44v. 2.


ἀπόλλυθαι, πεινεῖ, γίνεται καὶ γίνεται,

ГЫБНЯЩИХъ *loc. pl. in. ptc. mas. act.*

Διψε αἱρετοῦσαν τὸ ποκὼνενον εὐαγγελιεν ημῶν
βζ ГЫБНЯЩИХъ εστὸν ποκὼνενον:

εἴ δέ καὶ ἔστιν κεκάλυμμένον τὸ εὐαγγελεῖον
ἡμῶν, ἐν τοῦτος ἀκολημένοντος ἔστιν κεκάλυμ-
μένον;

= Sis. (гыбноущихъ)





Search criteria

Rendered form (like) Use equivalences ([show all](#)) Lemma v%Part of speech Index Morphology (_ is a wildcard) [morphology help](#)

S _ m _

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15

Order by

	order	priority
Rendered form	ascending <input type="button" value="▼"/>	first <input type="button" value="▼"/>
First occurrence	no <input type="button" value="▼"/>	none <input type="button" value="▼"/>
Lemma	no <input type="button" value="▼"/>	none <input type="button" value="▼"/>
Index	no <input type="button" value="▼"/>	none <input type="button" value="▼"/>
Part of speech	no <input type="button" value="▼"/>	none <input type="button" value="▼"/>
Morphology	no <input type="button" value="▼"/>	none <input type="button" value="▼"/>

Search is restricted to the following documents: Tr, Orb, VK, Mkd, Lesn, Grig, GreekTrans, Hlud, BT, ST, KR, Bon

page: 1 ▪ [2](#) [3](#) [4](#) [5](#) [6](#) [7](#) [8](#) [9](#) [10](#) [11](#) ▪ [Next page](#)go to page: items per page: font: size:

Rendered form	First occurrence	Lemma	Index	Part of speech	Morphology	#	Detail	Context
БАВИЛЛА	ST (1577)	БАВИЛЛА	o	S	S-m-----	1		
БАВИЛО	ST (1652)	БАВИЛЛА	o	S	S-m-----	1		
БАВИЛЫ	ST (1566)	БАВИЛЛА	o	S	S-m-----	3		
БАВИЛОНЬ	ST (27992)	БАВИЛОНЗ	o	S	S-m-----	3		
(БАВИЛОН)	ST (30806)	БАВИЛОНЗ	o	S	S-m-----	1		
БАВИЛОНОР	ST (30791)	БАВИЛОНЗ	o	S	S-m-----	1		
БАВИЛОНТ	ST (30781)	БАВИЛОНЗ	o	S	S-m-----	1		
БАВИЛЛА	Orbelsky triod (8486)	БАВИЛЛА		S	S-m-----	1		
БАВИЛОНТ	BT (9138)	БАВИЛОНЗ		S	S-m-----	4		



Search is restricted to the following documents: Tr, Orb, VK, Mkd, Lesn, Grig, GreekTrans, Hlud, BT, ST, KR, Bon

page: 1 ■ 2 ■ Next page

go to page: items per page: font: size:

	left part	form	right part
(—А— възвеличимъ вси члобѣжкообразие ти Христѣ боже на шь слава твоихъ	рабъ	и вѣнецъ вѣрныи възвеличавы жтробѣ рождашхъ та рабъ	отвѣсть быс(ть)
възѣжшѣ чисто мко(и)ты слаше впнѣмъ Христу прими мко(бы спас(е) твоихъ	рабъ	и мко(енина азъ тѣбѣ са мко(а мѣти Христована не	прѣстан
(П)онте и прѣвѣсните иже подвигомъ добрыми подвигыше са святы мко(и)чи	рабъ	недостоинъ ко Христу ходатан не забжадте да достоинъ	тѣчение постное
Иако/же Господъ/и/ аврами/е отвѣшав же клятви/ци рѣко шъ ємоу тзи юс(т)	рабъ	Божіи и урънцъ съврьшень епнис(ко)ль ру(е) къ нимъ	его
(зла ныи богы въса раско/паль/ес(т) и немогоша єго възлюбити въисти/ни	рабъ	юс(т) бого жиаго и вѣс речено/наа от (нега и/стинна	
дѣнѣбр Господнѣ потьшимса субо икнѣ и подвигнѣмса да сане/швра/щемъ Иако	рабъ	шнъ єгоже пришад (Господъ єго шврашеть пнтах/аса и	нерадаща тѣ/мжео
Иако ни го/сифон/ оуподко/енса ни блаженнѣи соуса/нѣ аш	рабъ	преданъ быс(т) егуптѣнн/и ради нѣ непокориса лыш/ни	



Current State

- 8 manuscripts, 700 000 forms
 - with keywords (lemma, POS, hom), correlation to other sources, translations
- Annotation tool - ACT
 - distributed annotation
 - direct web exporting
- Created conditions for application of NLP tools
- Possibility to process enormous card files