

**17/1/2014**

---



**National and Kapodistrian University of Athens  
Department of Linguistics**

# **Greek corpus building and analysis: The story so far and what is to follow**

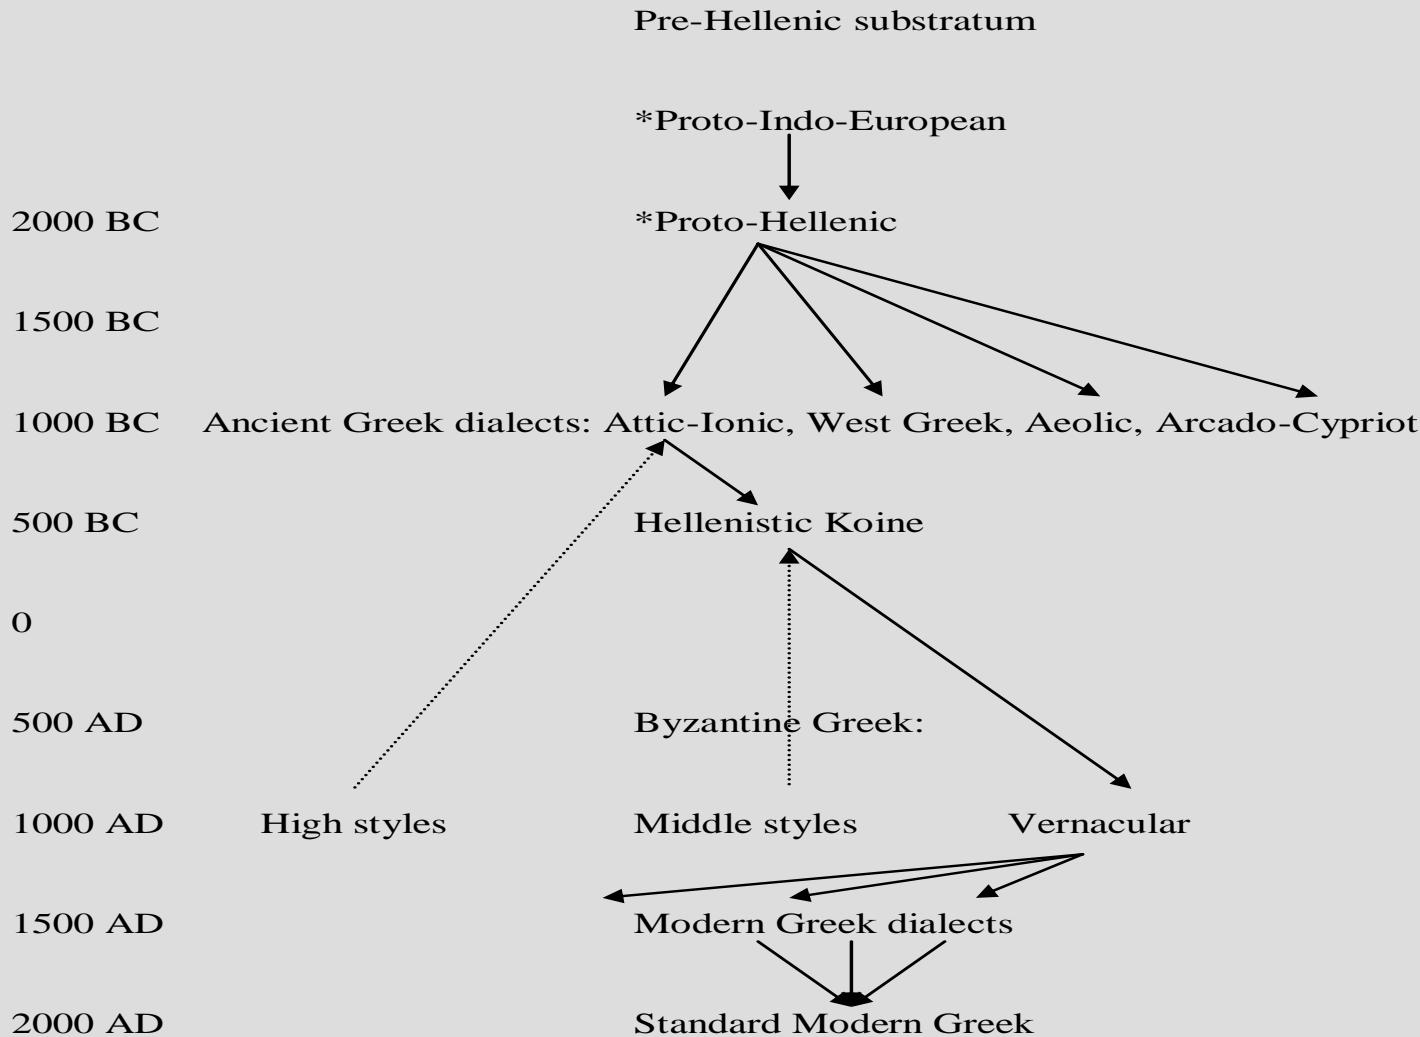
Dionysis Goutsos

## **Greek corpus building and analysis: The story so far and what is to follow**

---

- *Greek corpus building*
  - 1. Peculiarities of Greek
  - 2. Phases of development
- *Corpus-based analysis of Greek*
  - 3. Major findings on Greek
  - 4. Major needs and prospects
  - 5. Greek and corpus-based translation studies

# 1. Peculiarities of Greek



## 1. Peculiarities of Greek

---

- long historical tradition:
  - ▶ multiple continuities
  - ▶ genre and language varieties
- non-Western alphabet:
  - ▶ from ASCII to Unicode
  - ▶ ‘monotonic’ and ‘polytonic’ varieties
- aversion to empiricism
  - ▶ modern reference works (dictionaries and grammars: post-1998)
  - ▶ language resource development (lack of co-ordination and open-source tools)

## 2. Phases of development

---

Renouf (2007): English language corpora

- 1960s-1970s: the one-million word Small Corpus: standard, sampled: *LOB, Brown corpus*
- 1980s: the multi-million word Large Corpus: super-corpus: *Bank of English, BNC*
- 1990s: the 'Modern Diachronic' Corpus: dynamic, open-ended, chronological data flow: *FLOB, Frown*
- 1998-: the Web as corpus: cyber-corpus

## 2. Phases of development

### Greek corpora

- 1980s: literary corpora: *Erotokritos* (1986), Makriyannis (1992)

Γ159 “Νένα μου, λέγει ή Ἀρετή, φρόνιμα δασκαλεύγεις,  
Γ171 “Παιδί μου, λέγει ή νένα της, σφάνουσι τὰ λογιάζεις,  
Γ299 “Νένα μου, λέγει ή Ἀρετή, ἵντά 'ν' τὰ δασκαλεύγεις;  
Ε613 “Νένα, τσῆ λέγει ή Ἀρετή, τὸ γίνηκεν ἐγίνη  
Ε1133 “Αμε πέ, λέγει ή Ἀρετή, γλήγορα τοῦ κυροῦ μου

0908 λύσει/ καὶ σὰν ὄντας κρατεῖς κερὶ καὶ ἄνεμος σοῦ τὸ σβήσει// ἐκεῖνος ὅποὺ<sup>1</sup>  
1145 [οὐδὲ καπνίσματα μποροῦν οὐδὲ κεριὰ οὐδὲ θρόνοι// τὸν κόσμο ὅλο  
0415 νὰ μ' ἀφήσει/ ἐπά 'ν τ' ἀφτούμενο κερὶ ποὺ μελετᾶς νὰ σβήσεις// καὶ τὸ κορμὶ ὅποὺ  
0408 μηδ' εἶδα τὸ ποτέ μου,/ μά 'νεν κερὶν ἀφτούμενο ἐκράτουν καὶ ἡσβησέ μου//

(a) *Sacrifice of Abraham*

A0756 ΠΟΙ κ' ἐπόνει/ σὰν τὸ κερὶ ἀνελίγωνε κ' ἐφύρα σὰν τὸ χιόνι//  
E0923 ΡΩΤ ἀγάλια ἔχανετο σὰν τὸ κερὶ ὄντε σβήνη,/ ἥκλαψα κ' ἐλυπήθηκα πολλὰ  
Γ1102 ΦΡΟ κι ὥστα φυσήξης τὸ κερὶ ὅπού 'ψες, νὰ τὸ σβήσῃς// καὶ δῆ το καὶ  
B2391 ΠΟΙ κι οὐδὲ ψυχάρι οὐδὲ κερὶ οὐδὲ φωτιὰ οὐδὲ γράμμα/ τοῦ ἐπόμεινε  
B0757 ΠΟΙ κι αὐτὸς στὴν κεφαλὴν ἔνα κερὶ σβημένο'/ τὸν "Ανεμον ἀνάδια του ἡδειχνε  
E0414 ΠΟΙ τῶν ἀμματιῶν του ἡ λάμψη/ κερὶ σβηστὸν ἐφύλαγε καὶ πάγει ἐδὰ νὰ τ' ἄψῃ//  
B2177 ΠΟΙ οἱ τρεῖς τως σ' μιὰ μερά, Κερί, Ψυχάρι, Ἄμαξι/ μὲ πεθυμιὰ ἀνιμένασιν  
Γ1396 ΡΩΤ δὲ σ' εἶδα ποτέ μου,/ μά ἔνα κερὶν ἀφτούμενον ἐκράτουν κ' ἡσβησέ μου//  
Δ1763 ΠΟΙ λαβώσῃ// σὰ νά 'χεν εἰσται κέρινο, τέτοιας λογῆς διαβαίνει,/ στὸν κάμπο

(b) *Erotokritos*

## 2. Phases of development

### Greek corpora

- 1990s-2000s: two 'super-corpora'  
Hellenic National Corpus: <http://hnc.ilsp.gr>

The screenshot shows the ILSP Corpus website. At the top, there is a green header bar with the text "ILSP Corpus" in white. Below the header are five menu buttons: "User Details", "Text Selection", "Queries", "Statistics", and "Help". To the left of the header, there is a logo consisting of stylized letters "ΕΩΣΕΥ". The main content area has a light gray background. At the top of this area, it says "Hellenic National Corpus (HNC)™". Below that, the text "The ILSP Corpus" is centered. A paragraph of text follows, describing the corpus's development by the Institute for Language and Speech Processing, its size (over 47 million words), and its search capabilities. At the bottom of the main content area, there is a note about the availability of the whole corpus on the web and a link to the user guide. At the very bottom of the page, there is a "Greek Interface" link on the left and copyright information on the right.

**Hellenic National Corpus (HNC)™:**

The ILSP Corpus

The ILSP Corpus has been developed by the Institute for Language and Speech Processing. It currently contains more than **47.000.000** words of written texts and is constantly being updated. Users can retrieve parts of these texts in the form of whole sentences by making queries based on one to three words, lemmas or parts of speech. Furthermore, users can define the maximum distance between search items as well as the specific sub-corpus they wish to make queries in. Finally, users can also look for certain statistical data for words and lemmas.

The whole ILSP corpus is available on the web. A user guide, further details and more general information can be found in [help](#).

"Hellenic National Corpus"™ and "Ελληνικός Επαρχιακός Ελληνικός Γλωσσος"™ are trademarks (™) of the Institute for Language and Speech Processing.

[Greek Interface](#)

Hellenic National Corpus™ (HNC)  
Web Version 3.0  
Copyright © 1999-2009 ILSP  
All rights reserved  
For information: [hnc@ilsp.gr](mailto:hnc@ilsp.gr)

## 2. Phases of development

---

- HNC: currently 47 million words
  - lemmatized
  - Problems with HNC:
    - restricted range of text types (newspaper articles)
    - no spoken data
    - restricted text classification (mostly 'other')
    - restricted availability
- 
- > example of corpus building as separate from corpus analysis
  - > need for a representative/authoritative corpus of Greek

## 2. Phases of development

Corpus of Greek Texts (CGT):  
[www.sek.edu.gr](http://www.sek.edu.gr)

*πώς κι ἀπὸ ποῦ ἀκουμπάει τὸ μέγα στὸ ἄλφα*

Σάρια Ελληνικῶν Κειμένων

Σύνδεση  
Όνομα:   
Επιθετικό:

Σάρια Ελληνικῶν Κειμένων

Τα Σάρια Ελληνικῶν Κειμένων (ΣΕΚ) δημοπρατήθηκαν από την Ελληνική Δημοκρατία και είναι το πρώτο ελεκτρονικό σαρία κειμένων που παραδίδεται στα πάντα όρια προσβάσιμον και σχετικά εύκολαν για χρήση.

Τα Σάρια Ελληνικῶν Κειμένων αποτελούν πρώτη πανεπικόπια σειρά Ελληνικού λόγου και προέρχονται από την Επίκριτη Εργαστήρια Ποίησης και Πανεπικόπια Κύπρου (Πανεπιστήμιο Πατρών). Είναι προτίτλος ΤΥΒΑΓΡΑΣ (ειδικοποιημένο παρατελεσμένο έργο Επαγγελματικού Κοινωνικού Τοπίου και Εθνικού Πορεγκ ΕΠΙΑΕΚ II) (Παραπομπής πληροφοριών). Η υποστήθηκε από την πρόγραμμα «Κέρδισε» της Εθνικής και Καποδιστριακής Πανεπιτελίας Αθηνών (Εθνικό Πανεπιστήμιος, ιδιωτικός ιδρυματικός οργανισμός, υποδηματικός δικτύος Γειτνιάτρων).

Τα νέα δάστη την πλήρη κατάλογο των εργασιών του ΣΕΚ, παρέχεται εδώ.

Τα νέα παραδίδονται στο ΣΕΚ, αναφέροντας στις:

Δ. Γεωργός (2003). Σάρια Ελληνικῶν Κειμένων: Συζητήσεις και μλεντερ. Πρωτοβ. της δικής δινεβάσης Ελληνικός Γλωσσολογικός Λεξικός Κάτιος 28-29 Σεπτεμβρίου 2003. ΕΛΛΗΝΙΚΟΝ ΓΛΩΣΣΩΝ.

D. Goutzou (2012). The Corpus of Greek Texts: A reference corpus for Modern Greek. *Corpora* 3 (2), 29-44. <http://doi.org/10.1515/corp-2012-0003>

Επειγόντως Επειγόντως

## 2. Phases of development

---



- Size: 30 million words
- Synchronic: 1990-2010
- Monolingual-non-translated texts
- Mixed: spoken-written
- Classification by text type, medium etc.
- Reference corpus of Greek: basis for analysis & comparison

## 2. Phases of development

---

- Specialized corpora
  - ▶ Greek Language Portal: [http://www.greek-language.gr/greekLang/modern\\_greek/index.html](http://www.greek-language.gr/greekLang/modern_greek/index.html)  
(newspapers, school textbooks, poems by Seferis)
  - ▶ Spoken Discourse Corpus: <http://corpus-ins.lit.auth.gr/corpus/index.html>  
(everyday conversations, phone talk)
  - ▶ ongoing projects: University of Athens teaching and learner corpora

### 3. Major findings on Greek

---

- NLP applications
  - quantitative/variation studies
  - teaching and sociolinguistic applications
- 
- development of new norms
  - revisiting grammatical categories
  - phraseology
  - vocabulary change

### 3. Major findings on Greek

---

- Development of new norms: Greek connectives

<b>1<sup>st</sup> clause position</b>	<i>Academic</i>	<i>Opinion articles</i>	<i>Parliament speeches</i>	<i>TV interviews</i>
<i>andíθeta</i> 'in contrast'	65	89	56	88
<i>ára</i> 'so'	60	56	86	97
<i>epoménos</i> 'thus'	45	52	83	88
<i>eftixós</i> 'fortunately'	66	57	50	58
<i>sinepós</i> 'consequently'	55	76	97	100
<i>entútis</i> 'however'	77	-	-	100
<i>paróla aftá</i> 'in spite'	75	-	-	75
<i>próta- próta</i> 'primarily'	-	-	67	67
<i>siberasmatiká</i> 'in conclusion'	100	100	-	-

### 3. Major findings on Greek

---

- Development of new norms: Greek connectives

<b>2<sup>nd</sup> clause position</b>	Academic	Opinion articles	Parliament speeches	TV interviews
<i>akrivós</i> 'precisely'	50	45	47	48
<i>áraje</i> INTER. Particle	44	77	95	100
<i>lipón</i> 'so'	80	88	87	65
<i>ómos</i> 'but'	74	88	75	60
<i>práymati</i> 'in fact'	40	38	52	45

### 3. Major findings on Greek

---

- Revisiting grammatical categories:

Fragaki (2010): Greek adjectives

- new classification:
  - classifying
  - descriptive
  - evaluative
  - deictic
  - relational etc.
- evaluative & ideological role of adjectives
- shift from one category to another:
  - e.g. περίφημος [perífimos] 'famous'
    - from positive contexts in literature
    - to negative contexts in opinion articles ('infamous')

### 3. Major findings on Greek

---

- Phraseology

Ferlas (2012): 3 to 5 word clusters in 4 Greek and English text types (CGT vs. BNC baby)

- most frequent: stance/modality clusters

ΔΕΝ ΜΠΟΡΕΙ ΝΑ: it cannot

ΔΕΝ ΠΡΈΠΕΙ ΝΑ: it must not

ΘΑ ΜΠΟΡΟΥΣΕ ΝΑ: it could not

ΘΑ ΠΡΈΠΕΙ ΝΑ: it should

- referential, textual, thematic etc. clusters

### 3. Major findings on Greek

---

#### - Phraseology

Ferlas (2012): text type preferences

e.g. literature: personal clusters

ΜΕ/ΑΠ'Ο/ΣΤΑ Μ'ΑΤΙΑ ΤΗΣ/ΤΟΥ: *with/from/in his/her eyes*

ΣΤΑ Χ'ΕΡΙΑ/Χ'ΕΡΙ ΤΗΣ/ΤΟΥ: *in his/her hand(s)*

ΚΟΥΝΗΣΕ ΤΟ ΚΕΦΆΛΙ ΤΗΣ/ΤΟΥ: *moved her/his head*

ΑΠΟ ΤΟ ΣΤΟΜΑ ΤΟΥ: *from his mouth*

Η ΦΩΝΉ ΤΟΥ/ΤΗΣ: *his/her voice*

ΓΥΡΙΣΕ ΚΑΙ ΜΕ/ΘΗΝ ΚΟΙΤΑΞΕ: *turned around and looked at me/her*

### 3. Major findings on Greek

---

#### - Phraseology

Ferlas (2012): equivalent clusters

Ε'ΙΝΑΙ ΔΥΝΑΤΟΝ ΝΑ

IT IS POSSIBLE TO

ΔΕΝ Ξ'ΕΡΩ ΑΝ

I DON T KNOW WHETHER

ΘΑ ΉΘΕΛΑ ΝΑ

I D LIKE TO

ΣΤΗΝ ΆΚΡΗ ΤΟΥ

[AT/ON] THE EDGE OF THE

ΓΙΑ ΜΙΑ ΣΤΙΓΜΗ

FOR A MOMENT

ΜΕ ΤΗ ΒΟΗΘΕΙΑ [ΤΟΥ/ΤΩΝ]

WITH THE AID OF/WITH THE HELP OF

### 3. Major findings on Greek

---

#### - Phraseology

Ferlas (2012): non-equivalent clusters

ΚΟΥΝΗΣΕ ΤΟ ΚΕΦΑΛΙ ΤΟΥ ≠ SHOOK HIS HEAD

- |   |  |
|---|--|
| 1 | «Δεν έχεις άδικο» <b>κούνησε το κεφάλι</b> του συμφωνώντας.<br>“You’re right”, he shook his head <u>in agreement</u>                     |
| 2 | κι αυτός <b>κούνησε το κεφάλι</b> του πάνω κάτω, τάχα ότι καταλάβαινε<br>and he shook his head <u>up and down as if he understood</u>    |
| 3 | <b>Κούνησε το κεφάλι</b> του σαν να μην το πίστευε.<br>He shook his head <u>as if he did not believe this</u>                            |
| 4 | Ο Στέφανος <b>κούνησε το κεφάλι</b> με κατανόηση.<br>Stephanos shook his head <u>with understanding.</u>                                 |
| 5 | <b>Κούνησε το κεφάλι</b> του με αβεβαιότητα κι έσβησε το τσιγάρο<br>He shook his head <u>with uncertainty and put down his cigarette</u> |
| 6 | και <b>κούνησε το κεφάλι</b> διαμαρτυρόμενος.<br>and shook her head <u>in protest</u>  |

### 3. Major findings on Greek

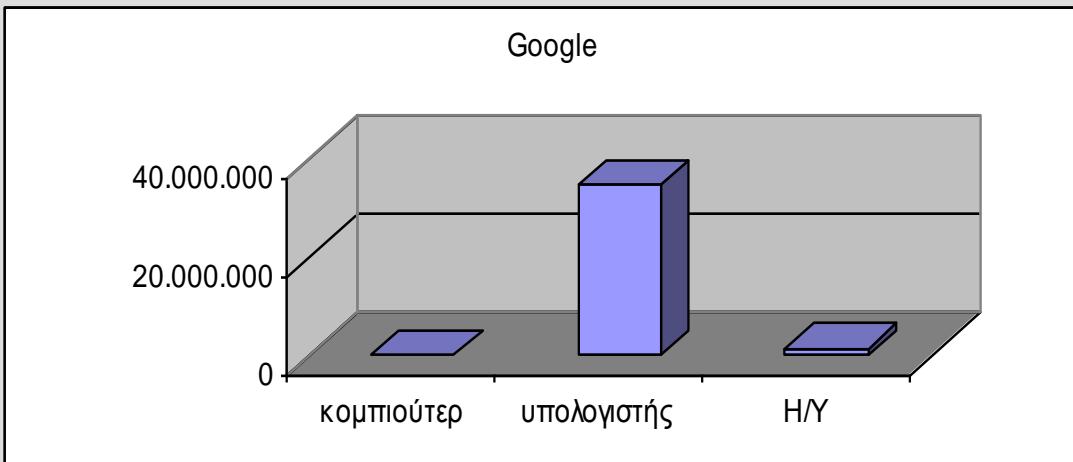
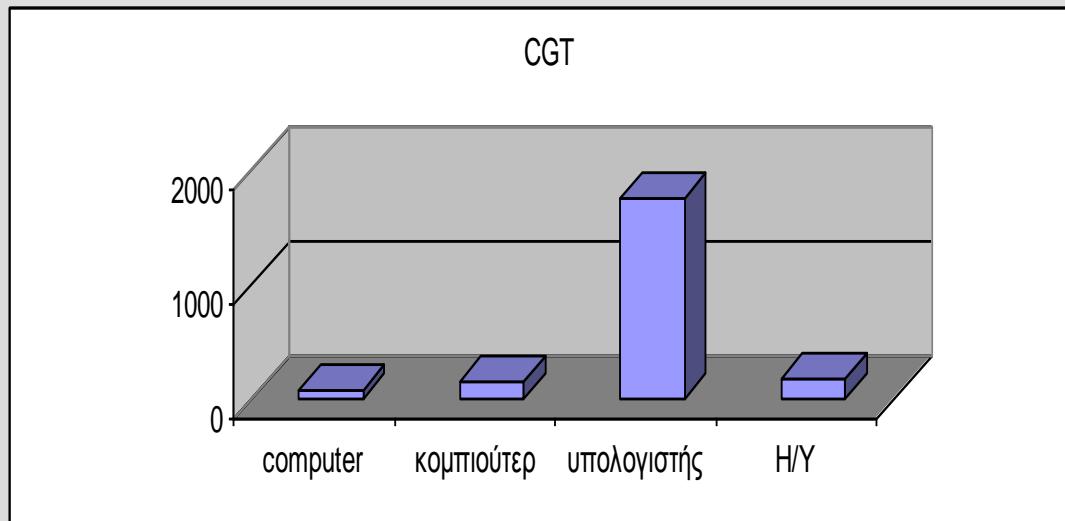
---

- Vocabulary change

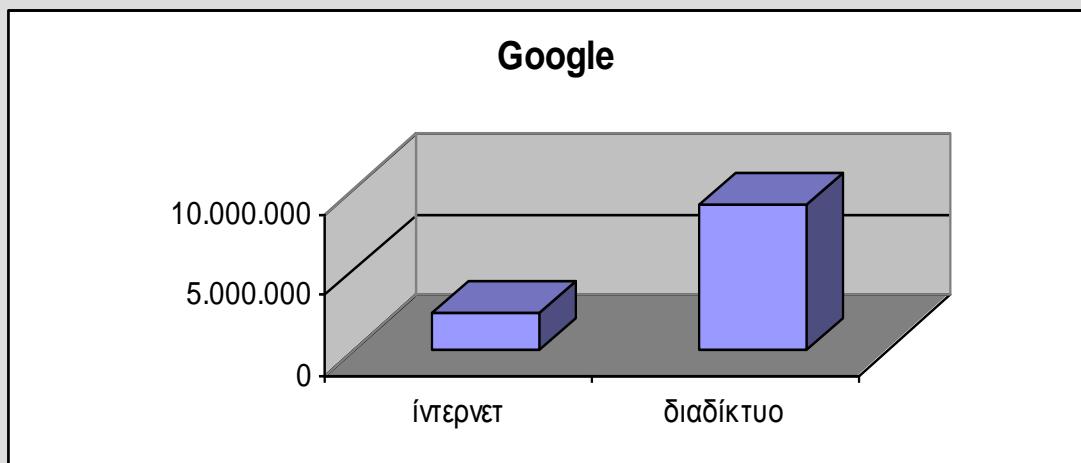
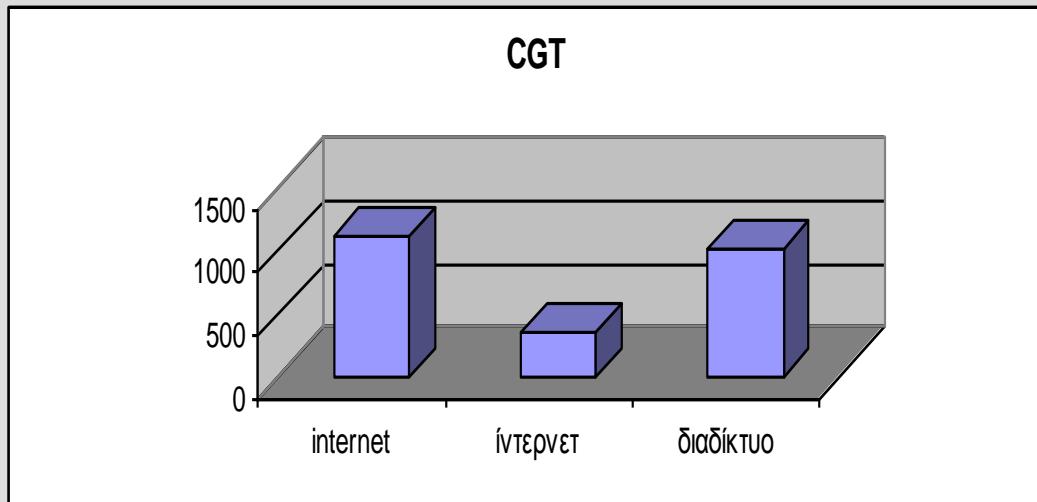
Options for introducing new vocabulary

- *computer*: loan
- *κομπιούτερ* [kompjúter]: loan/transliteration
- *υπολογιστής* [ipolojistís] (= calculator): neologism
  
- *internet*: loan
- *ίντερνετ/ιντερνέτ* [ínternet/internét]: loan/transliteration
- *διαδίκτυο* [δjaðíktio] (< δια=inter, δίκτυο=network): neologism

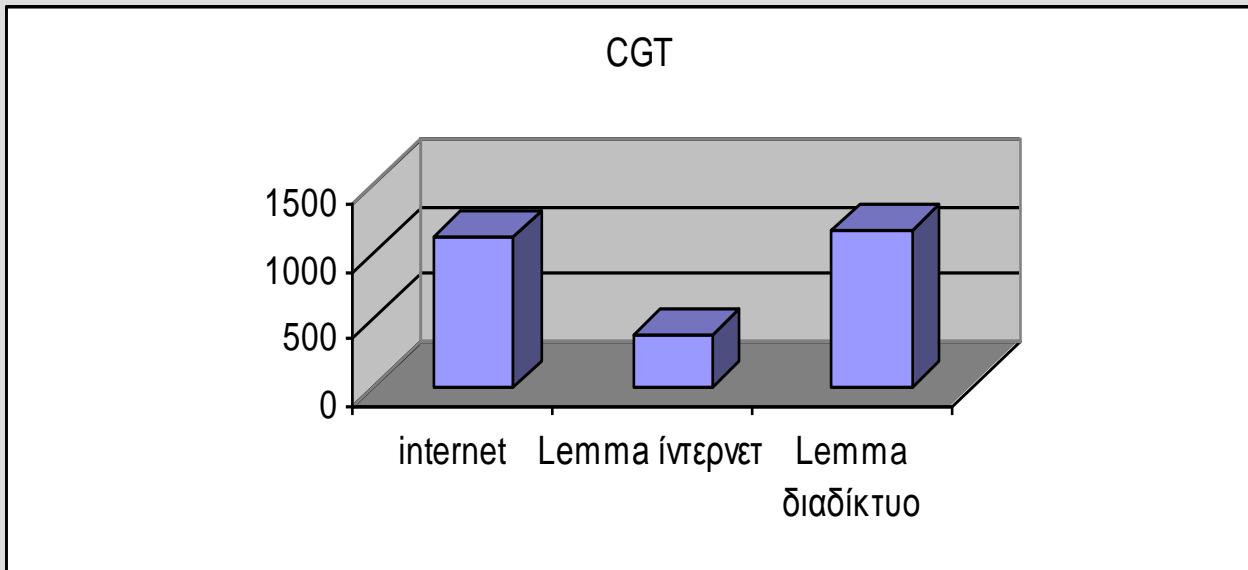
### 3. Major findings on Greek



### 3. Major findings on Greek



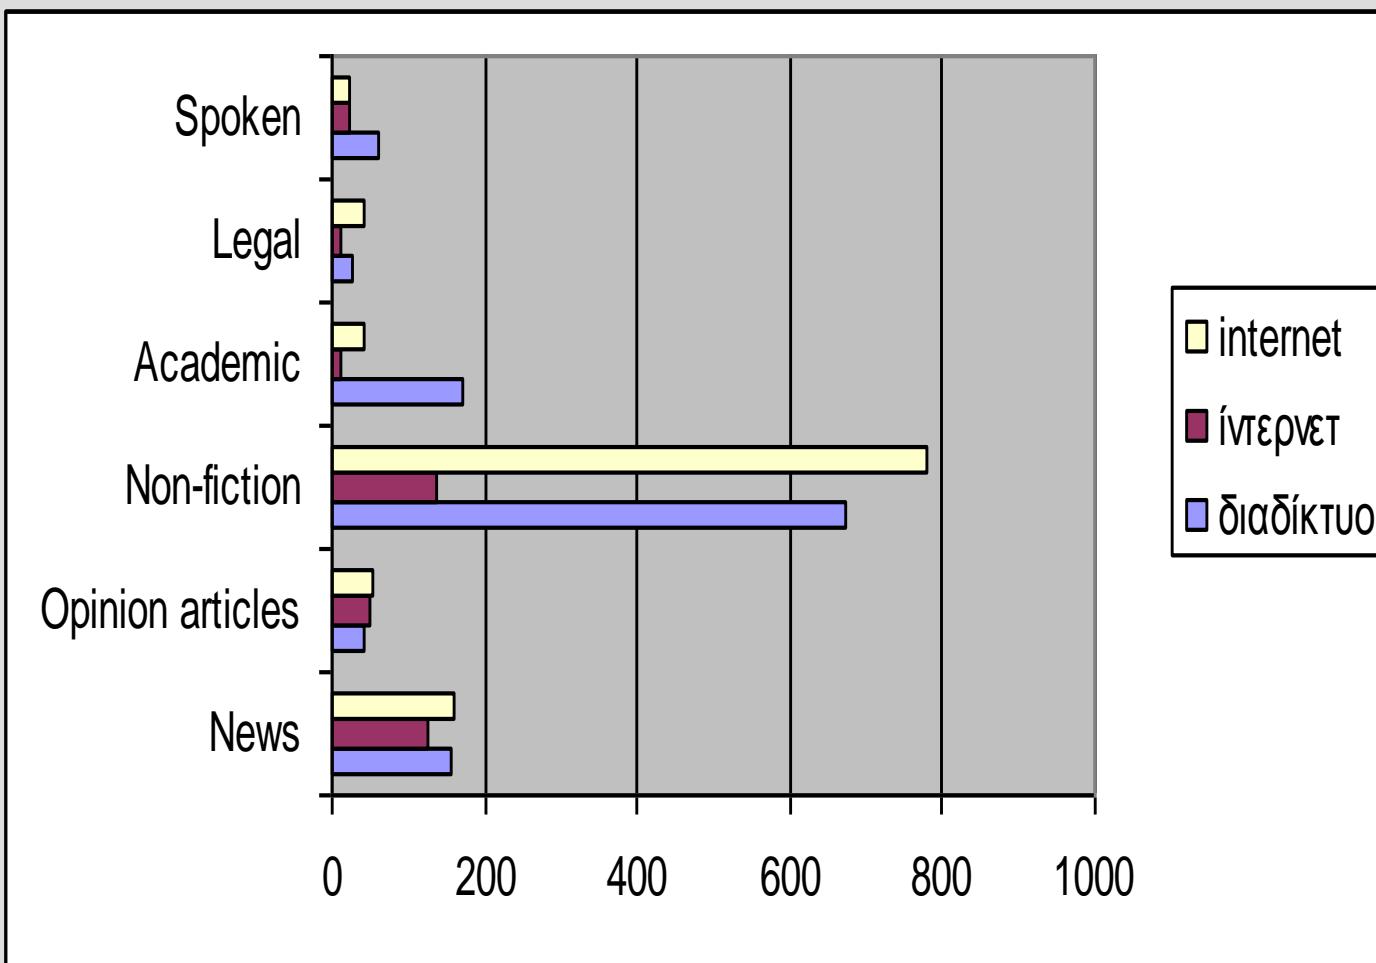
### 3. Major findings on Greek



ίντερνετ> ιντερνετικός, ιντερνετάκι, ιντερνέτια

διαδίκτυο> διαδικτυακός, διαδικτυωμένος, διαδικτύωση,  
διαδικτυάκι

### 3. Major findings on Greek



## 4. Major needs and prospects

---

- Diachronic corpora
  - ▶ *Diachronic Corpus of Greek of the 20<sup>th</sup> century:*  
<http://greekcorpus20.phil.uoa.gr>
  - ▶ ‘polytonic’ OCR
  - ▶ linking with *TLG* and Medieval Greek corpora
- Dynamic corpora: data after 2000
- NLP applications: availability, standardization

## 5. Greek and corpus-based translation studies

---

- Monolingual Greek corpora as sources of information  
    checking translations against Greek norms  
    e.g. placement of connectives

<i>ómos (%)</i>	1 <sup>st</sup> position	2 <sup>nd</sup> position	Other
Dik (1995)	21	<b>71</b>	8
Coelho (1999)	<b>74</b>	25	1
Pamouk (2007)	31	<b>67</b>	2

## 5. Greek and corpus-based translation studies

---

- Monolingual Greek corpora as sources of information  
checking translations against Greek norms

e.g. *perífimos*

1 περιέγραφαν φαντασιώσεις που περιλαμβάνονταν στο  
περίφημο βιβλίο για τις σεξουαλικές παρεκκλίσεις - βιβλίο  
Κοέλο (1999)

2 ο Τόκατ, στον τσαϊχανέ Σενλέρ, δίπλα ακριβώς στο  
περίφημο λουτρό Πιφβανέ, στο μπαρ, είμαι υπεύθυνος για τ  
Παμούκ (2007)

3 χο στίχο, το ποίημα. Έχει γράψει τους στίχους του  
περίφημου ποιήματος που ξέρουμε, όταν χτυπάει η πόρτα.  
Παμούκ (2007)

## 5. Greek and corpus-based translation studies

---

- Monolingual Greek corpora as sources of information  
checking translations against Greek norms  
e.g. *κούνησε το κεφάλι του/της* 'moved his/her head'

«Όχι». Ο Μίνι κούνησε το κεφάλι του με έμφαση. (Dick 1995)  
“No”. Mini shook his head no vigorously. (Dick 1991)

«Σωστά» είπε ο Κέβιν. Κούνησα το κεφάλι. (Dick 1995)  
“Right”, Kevin said. I nodded. (Dick 1991)

## 5. Greek and corpus-based translation studies

---

- Monolingual Greek corpora as sources of information

comparing norms between languages

cf. Gorjanc (2006) on Slovene:

- first, only the loan word occurs in the corpus
- when the Slovene variant appears, it immediately becomes a successful rival
- the use of the loan word gradually decreases
- however: *medmrežje* has not been accepted instead of *internet*

## 4. Greek and corpus-based translation studies

---

### - Bilingual corpora

From comparable corpora (Ferlas 2012) to parallel corpora (Tsoumari 2013):

e.g. frequency and range of translation choices

ST EN and

TT EL	FREQUENCY
και	1455
omitted	42
καθώς και	41
ενώ	10
αλλά και	8
ή	4
εξάλλου	1
μάλιστα	1
συνεπώς	1

ST EN but

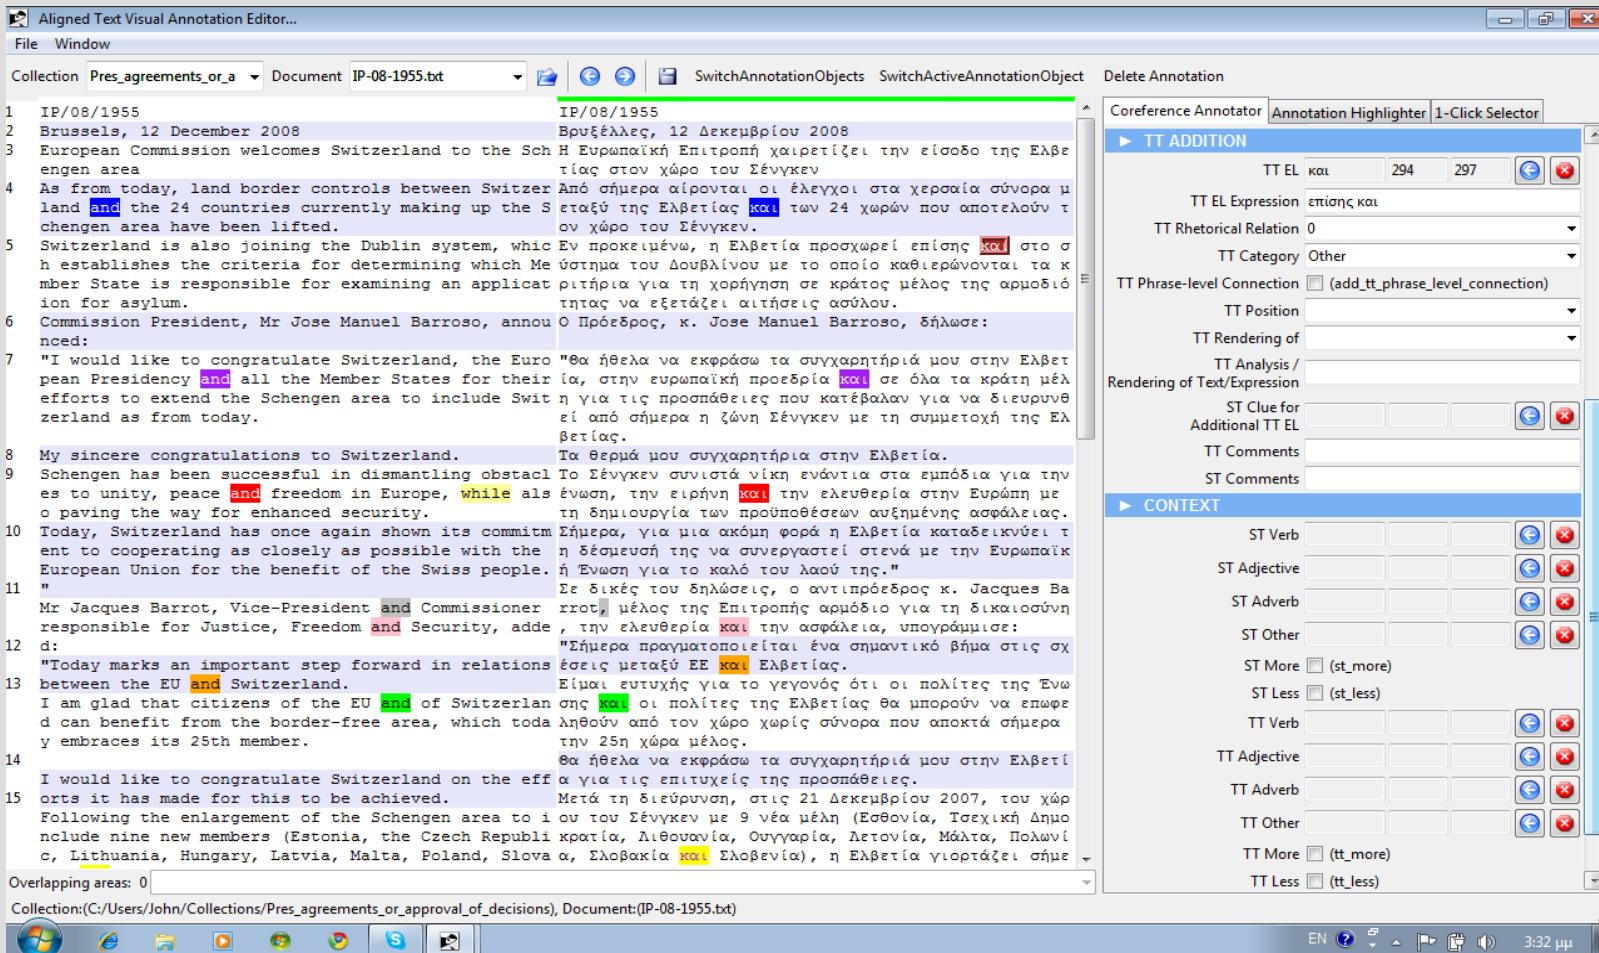
TT EL	FREQUENCY
αλλά	16
όμως	9
ωστόσο	4
αλλά και	3
omitted	2
ενώ	1
μολονότι	1
πάντως	1

ST EN however

TT EL	FREQUENCY
ωστόσο	7
εντούτοις	2
όμως	2
μολαταύτα	1
πάντως	1

## 4. Greek and corpus-based translation studies

- Tsoumari (2013): development of customized annotation tools for Greek



## 4. Greek and corpus-based translation studies

---

### - Conclusions:

more work is needed in the analysis of Greek monolingual corpora

> identification of norms

> comparison with translated text norms (check for simplification, explicitation, normalization, levelling-out; cf. Baker 1996)

more and more varied bilingual corpora, involving Greek and a broad range of other languages, are needed

corpus building and corpus analysis are closely intertwined