



# Τύποι πόρων προς συγκέντρωση Σενάρια χρήσης

Μαρία Γαβριηλίδου

Πένυ Λαμπροπούλου

Γιούλη Μπακαγιάννη

**ΙΕΛ /ΕΚ «Αθηνά»**

14 Μαΐου 2015



# Τι τύπους πόρων συγκεντρώνουμε;

# Δεδομένα και μεταδεδομένα

---

- ◆ **Δεδομένα:** το πρωτογενές γλωσσικό υλικό
- ◆ **Μεταδεδομένα:** η τεκμηρίωση των δεδομένων με βάση ένα συγκεκριμένο σχήμα περιγραφής
- ◆ Το CLARIN EL συγκεντρώνει τόσο **δεδομένα** όσο και **μεταδεδομένα**.

# Οργάνωση του υλικού σε τρεις κατηγορίες

---

- ◆ Μεταδεδομένα και πόροι στο CLARIN EL
- ◆ Μεταδομένα στο CLARIN EL και οι πόροι διαθέσιμοι από αλλού
- ◆ Μεταδεδομένα στο CLARIN EL, ενώ οι πόροι δεν είναι ψηφιοποιημένοι ή διαθέσιμοι ηλεκτρονικά

# Μεταδεδομένα & πόροι στο CLARIN EL: η βασική κατηγορία

- ◆ το CLARIN EL παρέχει τον πόρο και την τεκμηρίωσή του
- ◆ ο χρήστης μπορεί
  - να ψάξει στον κατάλογο με βάση την τεκμηρίωση του πόρου,
  - να εντοπίσει και να καταφορτώσει τον πόρο ή
  - να χρησιμοποιήσει κάποια υπηρεσία γλωσσικής επεξεργασίας και να πάρει τα αποτελέσματα στον υπολογιστή του.
- ◆ Το CLARIN EL φέρει την ευθύνη για τη διάθεση του πόρου, σύμφωνα με τους όρους διάθεσής του όπως καθορίζονται από τον πάροχο.

# Μεταδομένα στο CLARIN EL, αλλά όχι οι πόροι

---

- ◆ το CLARIN EL παρέχει την τεκμηρίωση του πόρου αλλά όχι τον ίδιο τον πόρο (τον οποίο δεν έχει στα αποθετήριά του)
- ◆ παρέχει απλώς σύνδεσμο για το σημείο όπου βρίσκεται ο πόρος, ο οποίος παρέχεται από άλλη υποδομή ή φορέα
- ◆ το CLARIN EL δεν φέρει καμία ευθύνη για την διαθεσιμότητα του πόρου

# Χωριστός κατάλογος μόνο με μεταδεδομένα

---

- ◆ ο πόρος δεν είναι διαθέσιμος διαδικτυακά ή δεν είναι καν σε ψηφιακή μορφή, όμως είναι χρήσιμος
- ◆ το CLARIN EL παρέχει την τεκμηρίωση και παραπέμπει στον δημιουργό/διαθέτη του πόρου
- ◆ ΔΕΝ είναι προτεραιότητα του CLARIN EL η συλλογή τέτοιου τύπου υλικού
- ◆ αν κριθεί χρήσιμο να καταγραφεί η ύπαρξη του πόρου, γίνεται τεκμηρίωσή του σε χωριστό κατάλογο "συμπληρωματικού υλικού", ώστε να μην υπάρξει σύγχυση με τους πραγματικούς πόρους

---

# Προδιαγραφές συγκέντρωσης πόρων

# Το υλικό που συγκεντρώνει το CLARIN EL

---

- ◆ ψηφιοποιημένα κείμενα γραπτού ή προφορικού (μεταγραμμένου) λόγου
- ◆ ηχητικά αρχεία καταγεγραμμένου προφορικού λόγου
- ◆ βίντεο
- ◆ λεξικά/γλωσσάρια
- ◆ συλλογές κειμένων
- ◆ ...

# Γλώσσα

---

- ◆ μονόγλωσσοι (Ελληνικά)
  - ◆ δίγλωσσοι ή πολύγλωσσοι  
(που περιλαμβάνουν Ελληνικά)
  - ◆ προτεραιότητα στα Νέα Ελληνικά
  - ◆ δεν αποκλείονται παλαιότερες μορφές και διάλεκτοι, απλώς είναι σε χαμηλότερη προτεραιότητα
  - ◆ [οι διαθέσιμες ΓΤ είναι για τα NE!]
-

# Μέσο

---

◆ Κείμενο

◆ Ήχος

◆ Βίντεο

◆ Εικόνα

# Κειμενικό είδος / επίπεδο λόγου

---

- ◆ σε οποιοδήποτε τομέα, επίπεδο λόγου ή κειμενικό είδος
  - λογοτεχνία / επιστήμες / τύπος ...
  - οικείο / επίσημο ύφος
  - άρθρα / μυθιστορήματα / δημόσια έγγραφα / συγγράμματα / επιστολές / αναρτήσεις σε κοινωνικά μέσα δικτύωσης ...

# Μορφότυποι κειμενικού υλικού

- ◆ txt
  - ◆ xml
  - ◆ html
  - ◆ doc/rtf
  - ◆ pdf
  - ◆ ppt
- 
- ◆ τελευταία προτεραιότητα:  
κείμενο σε μορφή εικόνας (tiff, jpg)
  - ◆ δακτυλόγραφο & χειρόγραφο → OXI

# Μορφότυποι ηχητικού υλικού & πολυμεσικού υλικού (βίντεο)

## ◆ Ηχητικό υλικό

- ηχητικό/ακουστικό αρχείο wav file
- Mp3
- απλή ορθογραφική μεταγραφή από απομαγνητοφώνηση
- φωνητική μεταγραφή σε IPA

## ◆ Πολυμεσικό υλικό

- Mp4
- avi

# Κωδικοποίηση

---

- ◆ UTF-8

# Ευκόνα

---

- ◆ jpg
- ◆ tiff
- ◆ pdf (όχι σκαναρισμένα)
  
- ◆ φωτογραφίες σκέτες → OXI
- ◆ φωτογραφίες με λεζάντες → NAI

# Λεξικά/Θησαυροί

- ◆ βέλτιστη επιλογή: το περιεχόμενό τους (=τα λήμματα), ώστε να είναι δυνατόν να αποθηκεύονται και να καταφορτώνονται από το CLARIN
  - σε αυτή την περίπτωση
    - LMF, tbx
    - txt, csv
    - xml, SKOS / RDF
- ◆ λιγότερο επιθυμητή επιλογή: διαθέσιμα μέσω διεπαφής, οπότε τα τεκμηριώνουμε και κάνουμε απλή παραπομπή στο url τους
- ◆ έντυπα: **OXI**, εκτός αν είναι εύκολα μετατρέψιμα σε ηλεκτρονικά επεξεργάσιμη μορφή

# Βάσεις δεδομένων

---

- ◆ Οι βάσεις δεδομένων αυτές καθαυτές δεν μπορούν να ενταχθούν στο CLARIN EL ως γλωσσικοί πόροι. Ωστόσο, το περιεχόμενό τους μπορεί (κατά περίπτωση).
  - ◆ Αν είναι βάσεις δεδομένων με κειμενικό υλικό (π.χ. βιβλιοκριτικές / βιβλιοπαρουσιάσεις) → **ΝΑΙ**, εφόσον μπορούμε να εξαγάγουμε τα κείμενα και να δημιουργήσουμε ένα ενιαίο dataset
    - π.χ. *το corpus των βιβλιοπαρουσιάσεων* στην περίπτωση αυτή, ισχύουν οι προδιαγραφές για το κειμενικό υλικό.

# Ευαίσθητα δεδομένα

---

- ◆ Πόροι με προσωπικά δεδομένα:  
δεκτά
  - αν έχει γίνει ή αν μπορεί να γίνει  
ανωνυμοποίηση
  - ή
  - αν υπάρχει η γραπτή συγκατάθεση  
των συμμετεχόντων

# Υπάρχουσες συλλογές κειμένων

---

- ◆ Προτιμητέα λύση: να τεκμηριωθεί και αποθηκευτεί στο CLARIN EL το περιεχόμενό τους ως ενιαίος (και επεξεργάσιμος από την υποδομή) πόρος, π.χ.
  - Οι δημοσιεύσεις του X Τμήματος ή
  - Οι δημοσιεύσεις πάνω στο X θέμα
- ◆ Ο αρχικός πόρος εξακολουθεί να διατίθεται όπως και πριν
- ◆ Λιγότερο προτιμητέα λύση: τεκμηρίωση και παραπομπή στο url τους

# Άλλου τύπου υλικό

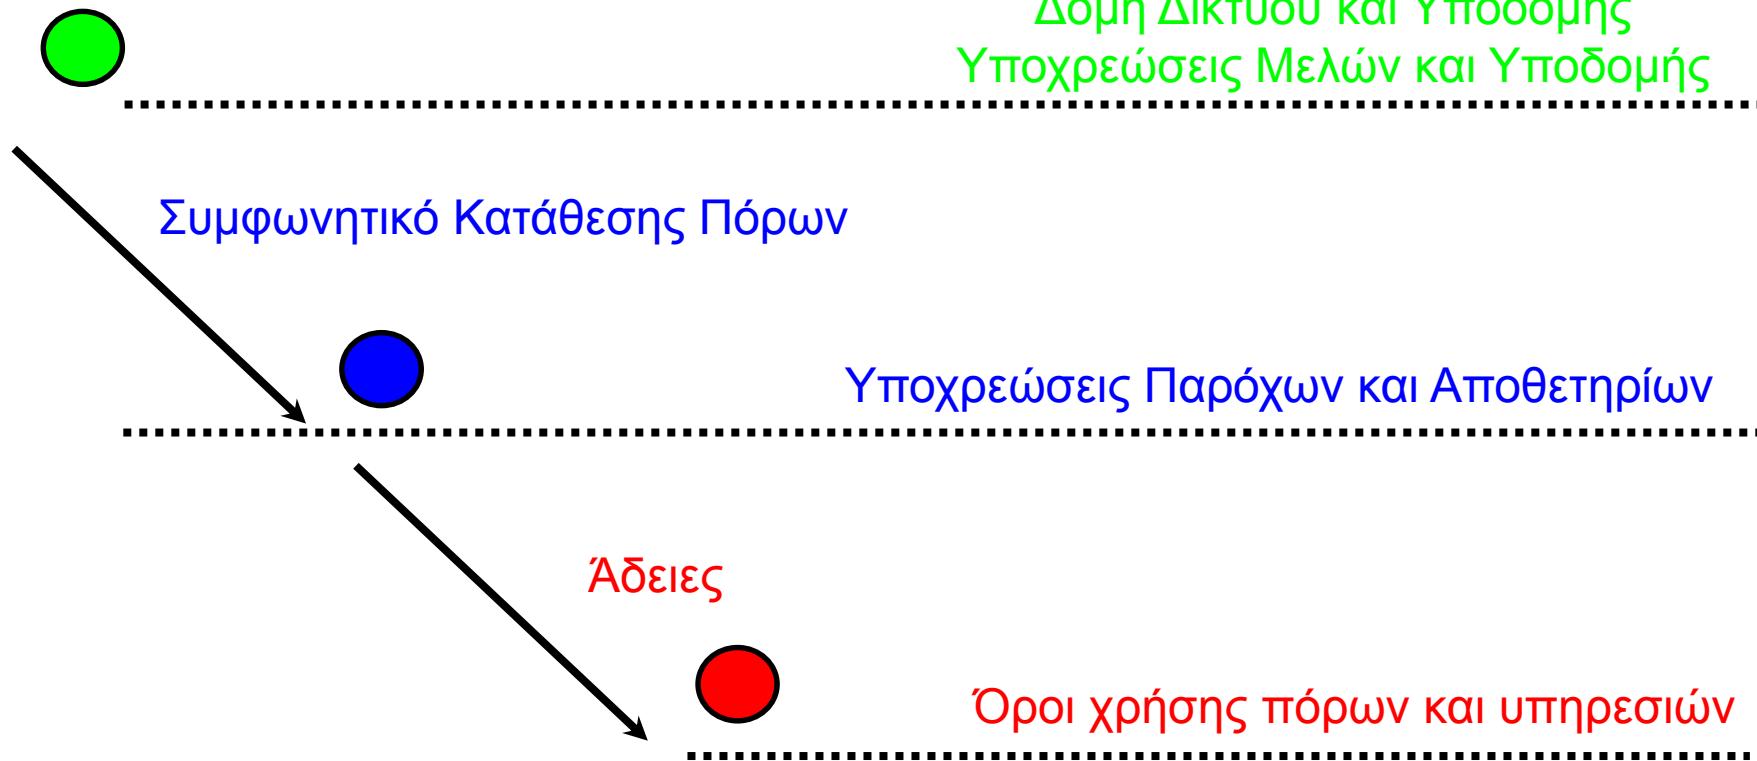
---

- ◆ υλικό που δεν εμπίπτει σε αυτές τις κατηγορίες αλλά αξιολογείται ως χρήσιμο
  - μπορεί να εντάσσεται στην κατηγορία των πόρων που έχουν μόνο μεταδεδομένα στο CLARIN με παραπομπή στο url τους
  - ή στην κατηγορία του απλού καταλόγου πληροφοριακού υλικού

# Νομικά ζητήματα

# Ροή νομικών διαδικασιών

Καταστατικό Δικτύου  
Ένταξη Μέλους



# Καταστατικό Δικτύου

---

- ◆ Υπογράφεται
  - μεταξύ των Μελών του Δικτύου
- ◆ Ορίζει
  - τον σκοπό, τις αρχές και τη δομή του Δικτύου
- ◆ Ρυθμίζει
  - τους τύπους, τα δικαιώματα και τις υποχρεώσεις των Μελών
- ◆ Προβλέπει
  - το σχήμα διοίκησης και τα όργανα του Δικτύου

# Συμφωνητικό Κατάθεσης Πόρων

---

- ◆ νομικό κείμενο το οποίο υπογράφεται μεταξύ Παρόχου και Υποδομής CLARIN EL
- ◆ με το οποίο ο Πάροχος δηλώνει ότι έχει (ή ότι έχει ξεκαθαρίσει) τα δικαιώματα διανοητικής ιδιοκτησίας και διάθεσης του πόρου
- ◆ εξουσιοδοτεί την Υποδομή να συμπεριλάβει τον πόρο στα Αποθετήριά της και να τον διαθέτει σύμφωνα με το σχήμα αδειοδότησης που ο ίδιος έχει επιλέξει
- ◆ και η Υποδομή δεσμεύεται για την απρόσκοπτη διάθεση του πόρου με τους ενδεδειγμένους και συμφωνημένους τρόπους.

# Ζητήματα διάθεσης

---

- ◆ κάθε πόρος που διατίθεται μέσω CLARIN EL πρέπει να έχει σαφές και ρητό καθεστώς διανοητικής ιδιοκτησίας
- ◆ ο πάροχος του πόρου πρέπει να κατέχει τα δικαιώματα διάθεσης (τα οποία βεβαίως διατηρεί) και
- ◆ ορίζει τους όρους με τους οποίους ο πόρος θα διατίθεται μέσω CLARIN EL

# Αρχές διάθεσης

- ◆ στόχος είναι οι πόροι να είναι ελεύθερα διαθέσιμοι
- ◆ για κάθε πόρο παρέχεται μία άδεια χρήσης με ξεκάθαρους όρους
- ◆ ωστόσο, υπάρχει μέριμνα για τον σεβασμό
  - των υφισταμένων πνευματικών δικαιωμάτων των πόρων
  - των διαφορετικών απαιτήσεων των παρόχων

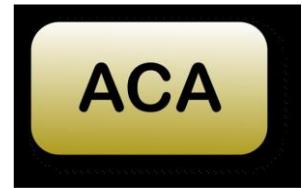
# Κατηγοριοποίηση πόρων CLARIN ανάλογα με τη χρήση

## ◆ ελεύθερα διαθέσιμοι (Publicly Available)

- Creative Commons 0 ή
- Open Database License (ODbL)



## ◆ για ακαδημαϊκή / ερευνητική χρήση



## ◆ χρήση υπό περιορισμούς

- πρόσθετοι περιορισμοί ηθικού χαρακτήρα ή
- σχετικοί με προστασία δεδομένων



# Ζητήματα διανοητικής ιδιοκτησίας και αδειοδότησης

- ◆ Οι πρότυπες άδειες χρήσης του CLARIN EL περιλαμβάνουν
  - **άδειες Creative Commons** (ξεκινώντας από τις Creative Commons Zero)
  - **άδειες META-SHARE “No Redistribution”**, που επιτρέπουν την χρήση και αξιοποίηση πόρων, δίνοντας στον κάτοχο του πόρου πλήρη έλεγχο μέσω της απαγόρευσης της αναδιανομής
  - άδειες CLARIN ERIC
  - άδειες ανοικτού λογισμικού για εργαλεία και υπηρεσίες
- ◆ Θα λαμβάνονται υπόψη οι υπάρχουσες άδειες διάθεσης

# Σενάρια χρήσης γλωσσικών πόρων, τεχνολογιών και υπηρεσιών γλωσσικής επεξεργασίας

# Σενάρια γλωσσικής έρευνας

---

- ◆ Εντοπισμός φωνημάτων και των συνδυασμών τους σε corpus προφορικού λόγου, είτε στην αρχική του μορφή (ηχητικό υλικό) είτε στην ορθογραφική ή φωνητική του μεταγραφή.
- ◆ Σύγκριση της στατιστικής συχνότητας εμφάνισης κυρίων ονομάτων (τοπωνυμίων, ανθρωπωνυμίων, κτλ.) σε διαφορετικούς πόρους.
- ◆ Εντοπισμός συντακτικών σχημάτων / δομών σε κείμενα.

# 'Ομως ...

**Οι γλωσσικοί πόροι και η  
γλωσσική τεχνολογία δεν είναι  
πολύτιμα μόνο για τους  
γλωσσολόγους ...**

# Σενάριο 1

---

- ◆ **Θέμα:** η μελέτη της άποψης διαφόρων πολιτικών για την κρίση
- ◆ **Υλικό:** επιλογή πόρου κειμένων που προέρχεται από τον Τύπο
- ◆ **Αναζήτηση:** δηλώσεων / συνεντεύξεων / άρθρων
  - των συγκεκριμένων πολιτικών
  - με θέμα την κρίση
- ◆ **Εντοπισμός** του υλικού: με τη βοήθεια γλωσσικών εργαλείων που αναγνωρίζουν λέξεις σχετικές με το θέμα
- ◆ **Ανάλυση** του υλικού:
  - ποσοτική ανάλυση με στατιστικά εργαλεία
  - ποιοτική ανάλυση με γλωσσικά εργαλεία

# Σενάριο 2

- ◆ **ανάλυση πολιτικού λόγου:** συγκέντρωση πολιτικών κειμένων, ηχογραφήσεων & βίντεο από διάφορες πηγές (π.χ. αρχεία πολιτικών ιδρυμάτων, Αρχείο EPT, ΕΟΑ, κτλ.)
- ◆ **προπαρασκευή**
  - για ηχητικά αρχεία: μεταγραφή σε γραπτό λόγο
  - για βίντεο: επισημείωση κινήσεων/χειρονομιών/εκφράσεων λόγου & σχέσεων μεταξύ τροπικοτήτων
  - για κείμενα: λημματοποίηση, μορφοσυντακτική επισημείωση, συντακτική ανάλυση, σημασιολογική επισημείωση (π.χ. λέξεις με συναισθηματικό φόρτο κτλ.)
- ◆ **ανάλυση/μελέτη**
  - στατιστική επεξεργασία (π.χ. συχνότητα λημμάτων, γραμματικών φαινομένων)
  - μελέτη τροπικοτήτων (π.χ. σύνδεση συγκεκριμένων χειρονομιών με ορισμένη στάση του ομιλητή)
- ◆ δυνατότητα μελέτης διαχρονικά, ανά ομιλητή, σε άλλες γλώσσες ...

# Σενάριο 3

- ◆ **Θέμα:** μελέτη της θέσης της γυναικας στη μεσαιωνική εποχή με βάση τα ιπποτικά έπη και τα ακριτικά τραγούδια.
- ◆ **Με τη βοήθεια**
  - του εργαλείου εξαγωγής κυρίων ονομάτων ο ερευνητής επιλέγει όλα τα κύρια ονόματα θηλυκού γένους
  - του μορφοσυντακτικού αναλυτή επιλέγει τα επίθετα και τις μετοχές που τα συνοδεύουν
  - του εργαλείου εξαγωγής συμφραστικών πινάκων αντλεί όλες τις προτάσεις που περιλαμβάνουν αυτά τα πρόσωπα.
  - στατιστικών εργαλείων αναλύει ποσοτικά αυτό το σώμα υλικού
- ◆ **Αξιολόγηση και ερμηνεία** των αποτελεσμάτων των εργαλείων γλωσσικής τεχνολογίας από τον ειδικό

- ◆ **Θέμα:** Μελέτη των κινημάτων του 20<sup>ού</sup> αιώνα από υλικό εφημερίδων.
- ◆ Ο μελετητής
  - αναζητά τις οντότητες που εμφανίζονται στα κείμενα (άτομα, κόμματα, οργανώσεις κ.λπ.) με το εργαλείο αναζήτησης ονοματικών οντοτήτων
  - ζητά από την εφαρμογή να του φέρει όλα τα σημεία που εμφανίζονται αυτές οι οντότητες
  - ζητά από την εφαρμογή να κάνει ποσοτική ανάλυση (στατιστική συχνότητα) της εμφάνισης των οντοτήτων αυτών
  - ζητά από την εφαρμογή να κάνει συντακτική ανάλυση των προτάσεων αυτών για να δει τα γεγονότα με τα οποία συνδέεται η κάθε οντότητα (parsing & event extraction)

# Σενάριο 5

- ◆ Λεξικογραφία: κατάρτιση λημματολογίου & κωδικοποίηση λήμματος
- ◆ επιλογή γλωσσικού υλικού
  - επιλογή από υφιστάμενους πόρους
  - συγκέντρωση νέων κειμένων από διαδίκτυο, για δημιουργία νέου πόρου
- ◆ επεξεργασία με εργαλεία υποδομής
  - λημματοποιητές και μορφοσυντακτικοί επισημειωτές
  - στατιστικά εργαλεία μέτρησης συχνοτήτων
  - εργαλεία δημιουργίας συμφραστικών πινάκων
  - εργαλεία συντακτικής ανάλυσης
  - εργαλεία εξαγωγής ορολογίας από κείμενα...

# Σενάριο 6

---

- ◆ Εξαγωγή ορολογίας από κείμενα
  - Επιλογή πόρου στον συγκεκριμένο τομέα
  - Λημματοποίηση και μορφοσυντακτική επισημείωση
  - Χρήση εργαλείου εξαγωγής ορολογίας
  - Επεξεργασία καταλόγου όρων από ειδικούς του τομέα για επαλήθευση

# Σενάριο 7

- ◆ Αυτόματη εξαγωγή πληροφορίας από επιστημονικές δημοσιεύσεις στην ιατρική ή τη νομική επιστήμη
  - γονίδιο X σχετίζεται με ασθένεια Y
  - νόμος X τροποποιεί νόμο Y
- ◆ Αναζήτηση και ανάκτηση σχετικών δημοσιεύσεων με βάση οντολογίες, θησαυρούς ή λέξεις κλειδιά
- ◆ Αναγνώριση οντοτήτων και σχέσεων μεταξύ τους με χρήση εξειδικευμένων εργαλείων
  - Αναγνώρισης και εξαγωγής ορολογίας
  - Αναγνώρισης και εξαγωγής ονομάτων
  - Αναγνώρισης και εξαγωγής γεγονότων
  - Υπολογισμού των συντακτικών σχέσεων μεταξύ τους

# Άλλα σενάρια;

---

- ◆ Παρουσιάσαμε κάποια από τα σενάρια που έχουν ήδη διατυπωθεί από ερευνητές χρήστες γλωσσικών πόρων και τεχνολογιών
- ◆ Να τα εμπλουτίσουμε σύμφωνα με τις δικές σας ανάγκες;
  - Ποιος είναι ο πόρος που χρειάζομαι;  **κίτρινο**
  - Ποια είναι η υπηρεσία που χρειάζομαι;  **ροζ**
  - Ποιο είναι το σενάριό μου;  **πορτοκαλί**