



ΕΛΛΗΝΙΚΗ ΔΗΜΟΚΡΑΤΙΑ

Εθνικόν και Καποδιστριακόν
Πανεπιστήμιον Αθηνών

— ΙΔΡΥΘΕΝ ΤΟ 1837 —

«ΑΠΟΛΛΩΝΙΣ»

Γλωσσικοί πόροι στο ΕΚΠΑ: Υποδομή, χρήση και εργαλεία

Ειρήνη Φλώρου

ΕΚΠΑ, 01/03/2019

Στόχοι

- Μετατροπή ανεπεξέργαστων δεδομένων σε χρήσιμη πληροφορία χωρίς εξαντλητική επισημείωση
- Συνόψιση πληροφορίας κειμένου σε διαγράμματα με σημασία
- Αναπαράσταση της γνώσης με πολλαπλούς τρόπους
- Πλήρης κατανόηση
- Συγκράτηση πληροφορίας από τον χρήστη

Δυνατότητες

1. Εξόρυξη πληροφορίας
2. Σύγκριση δεδομένων
3. Αναγνώριση προτύπων

Κατηγορίες τεχνικών οπτικοποίησης δεδομένων

1. αποκάλυψη περιεχομένου εγγράφων
2. απεικόνιση ομοιότητας εγγράφων
3. οπτικοποίηση συναισθημάτων που διατυπώνονται στο κείμενο
4. μελέτη ενός corpus στο οποίο ανήκει ένα έγγραφο
5. Ανάλυση δεδομένων συγκεκριμένου corpus π.χ. από δεδομένα μέσων κοινωνικής δικτύωσης, ηλεκτρονικές ειδήσεις, ποίηση

Γλωσσικά δεδομένα του CLARIN:EL

- Α. Κειμενικής μορφής
- Β. Προφορικού λόγου (ηχογραφήσεις)

Από ένα εύρος επιστημονικών πεδίων: νομικά σώματα κειμένων, ιατρικά λεξικά, οικονομικά και πολιτικά κείμενα, κείμενα σχετικά με την επιστήμη των υπολογιστών, τις γεωργικές επιστήμες, τη γεωλογία κ.ά.

Γλωσσικοί πόροι του CLARIN:EL

491 ψηφιακοί γλωσσικοί πόροι

- 400 σώματα κειμένων
- 35 εργαλεία επεξεργασίας
- 46 λεξικά

Υπηρεσίες γλωσσικής επεξεργασίας του CLARIN:EL

1. Λεκτικής ανάλυσης
2. Αναγνώρισης λέξεων, ορίων προτάσεων και μερών του λόγου
3. Μορφολογικής και συντακτικής ανάλυσης
4. Αναγνώρισης ονοματικών οντοτήτων, ορολογίας, άποψης και συναισθήματος

Τεχνικές οπτικοποίησης των δεδομένων του CLARIN:EL

1. Συννεφώλεξο (word cloud / tag cloud)
2. Γράφημα στοιβάδας (sunburst)
3. Γράφημα t-sne

Χαρακτηριστικά συννεφόλεξου

1. Ευανάγνωστη γραμματοσειρά
2. Η ιδιαίτερα βαρύνουσα λέξη αποδίδεται στο κέντρο του σύννεφου
3. Ζωντανά χρώματα για την οπτικοποίηση σημαντικών λέξεων
4. Επιλογή μεγέθους του σύννεφου από τον χρήστη
5. Χρήση λίστας stop words του ΣΕΚ


[illegible]

[illegible]

Χαρακτηριστικά γραφήματος στοιβάδας

- Ακτινωτή απεικόνιση των δεδομένων
- Το κοινό χρώμα αποδίδει και κοινή ιδιότητα των δεδομένων
- Η γωνία κάθε φέτας είτε διαιρείται ισόποσα κάτω από τον γονικό της κόμβο είτε μπορεί να είναι ανάλογη με μια προκαθορισμένη τιμή
- Χρήση λίστας stop words του ΣΕΚ

Γράφημα στοιβάδας (sunburst)




Γράφημα t-sne

Ομαδοποίηση των λέξεων με κριτήριο αν οι
διανυσματικές τους απεικονίσεις στον
γεωμετρικό χώρο είναι κοντά


Χαρακτηριστικά γραφήματος t-sne

1. Ο χρήστης μπορεί να επιλέξει μεταξύ τριών μοντέλων (word2vec, fasttext, Glove) για την εκπαίδευση
2. Ο χρήστης μπορεί να αλλάξει τον αριθμό των ομάδων μεταξύ των οποίων θα διαμοιραστούν οι λέξεις του κειμένου (από 2 έως όσες είναι οι λειτουργικές λέξεις του κειμένου)
3. Χρήση λίστας stop words του ΣΕΚ


Εργαλεία οπτικοποίησης δεδομένων σε άλλες γλώσσες I




Εργαλεία οπτικοποίησης δεδομένων σε άλλες γλώσσες II




Εργαλεία οπτικοποίησης δεδομένων σε άλλες γλώσσες IV




Εργαλεία οπτικοποίησης δεδομένων σε άλλες γλώσσες V



Γλωσσικό εργαλείο (topic visualization) που θα ολοκληρωθεί προσεχώς



Γλωσσικό εργαλείο (DocuCompass) που θα ολοκληρωθεί προσεχώς



Γλωσσικό εργαλείο (Graph) που θα ολοκληρωθεί προσεχώς

