

I corpora linguistici

- Cos'è un “**corpus**”?
 - È un termine che può indicare qualunque **testo in forma scritta o parlata**.
 - Nella linguistica moderna il termine indica un **insieme molto grande di testi**, in formato leggibile da un calcolatore, che rappresentino una particolare varietà od utilizzo di una lingua.
- Esistono tipi diversi di corpora:
 - possono concernere la lingua scritta o parlata (trascritta), antica o moderna;
 - possono consistere di interi libri, giornali, riviste, discorsi o di estratti di lunghezza variabile.

Classificazioni dei corpora

- Esiste la seguente suddivisione dei corpora:
 - **corpora generali**: non riguardano un singolo tipo di testo o argomento (es.: **British National Corpus**, <http://www.natcorp.ox.ac.uk/>);
 - **corpora di “sottolinguaggi”**: sono composti da testi che riguardano una varietà di una lingua (es.: varietà dialettale o inerente ad un particolare argomento);
 - **corpora paralleli**: sono composti dagli stessi testi tradotti in più lingue;
 - **corpora confrontabili**: sono composti da testi “simili” (il criterio di similarità è variabile) scritti in più lingue o varietà di una lingua: lo scopo è quello di confrontare l’uso di lingue diverse in circostanze comunicative simili.

Corpora elettronici

- I corpora elettronici possono includere il testo in due forme:
 - in forma semplice, senza informazioni aggiuntive,
 - con informazioni linguistiche aggiuntive (annotazioni o marcatori).
- Le informazioni in un corpus annotato possono essere di varia natura:
 - grammaticali,
 - sintattiche,
 - semantiche,
 - storiche,
 - ...

Origini storiche

- L'idea di utilizzare collezioni di testi nel campo della linguistica risale al Medioevo, quando si iniziò a:
 - produrre delle liste di tutte le parole di certe categorie di testi unitamente al loro contesto di utilizzo (processo che oggi viene chiamato “concordancer”),
 - calcolare le frequenze d'uso delle parole nei testi e produrre una lista di quelle maggiormente utilizzate.
- Il **vantaggio** degli studiosi dei nostri tempi è la **disponibilità del calcolatore** per gestire ed analizzare i corpora.

La prima generazione

- La prima generazione di corpora elettronici iniziò con il **Brown Corpus of Standard American English**.
- Tale corpus consiste di **un milione di parole** di testi americani stampati nel 1961. I testi furono scelti in proporzioni diverse da varie categorie:
 - stampa (reportage, editoriali ecc.),
 - letteratura scientifica,
 - ...
- Al giorno d'oggi tale corpus viene ormai ritenuto “piccolo” e leggermente datato, anche se per lungo tempo è stato uno dei pochi corpora elettronici disponibili.

La prima generazione

- Il **London-Lund Corpus of Spoken British English** (LLC) è un altro esempio di corpus “piccolo” (**100** testi di circa **5.000** parole ognuno).
- LLC è stato il primo corpus elettronico di una lingua parlata.
- I testi sono stati classificati in categorie come:
 - conversazioni spontanee,
 - orazioni,
 - ...
- Il tutto è stato trascritto in modo ortograficamente corretto e annotato con informazioni prosodiche.

Corpora di grandi dimensioni

- Nonostante i primi corpora si fossero resi utili per molti studi linguistici, cominciava a nascere l'esigenza di avere a disposizione grandi collezioni di parole (ad es. per la compilazione di dizionari).
- Nel 1987 nasce il Collins Cobuild English National Dictionary con circa 20 milioni di parole.
- Nel 1991 nasce la Bank of English (BoE) che nel 1996 contava 320 milioni di parole e rappresenta un monitor corpus (ovvero, un corpus che cresce con i cambiamenti della lingua corrente).
- Nel 1995 nasce il British National Corpus (BNC) con 100 milioni di parole (il BNC tuttavia è finito, ovvero, non vengono aggiunte nuove parole).

Corpora specializzati

- **Corpora “storici”:**
 - The Helsinki Corpus of English Texts: 1,5 milioni di parole estratte da testi inglesi antichi, medievali e dei primi secoli dell’era moderna.
 - Lampeter Corpus of Early Modern English Tracts: opuscoli e versi pubblicati dal 1640 al 1740.
- **Corpora relativi a campi specifici:**
 - Air Traffic Control Corpus,
 - TRAINS Spoken Dialogue Corpus.
- **Corpora internazionali/multilingue:**
 - English-Norwegian Parallel Corpus
 - English Turkish Aligned Parallel Corpora.

Modi di utilizzo

- Cercare il significato di una parola.
- Confrontare due sinonimi/parole simili.
- Studiare gli usi di una parola in contesti differenti.
- Capire che preposizione usare.
- Controllare l'ortografia di una parola.

W3-Corpora

- Un insieme di corpora elettronici online (con motore di ricerca) è disponibile all'URL

`http://clwww.essex.ac.uk/cgi-bin/w3c/w3c:`

Corpus Access

PROTOTYPE F

1. Corpus Selection

Press the **CORPUS** button, to enter a corpus.

Selezione del corpus.

2. Search String

Press the **STRING** button, to enter a search string.

3. Submit Query

Once a corpus has been selected and a search string entered you may proceed further.

Comments and Suggestions

If you have any comments or suggestions please let us know, thank-you.


Esempio di utilizzo

HELP

Corpus Selection

ACCESS

1. Corpus

 The Gutenberg Project, a collection of electronic texts.

2. Confirm Choice

Press the **CONFIRM** button, once you have made your selection.

CONFIRM

Esempio di utilizzo

HELP

Subcorpus
Selection

The Gutenberg Project, a collection of electronic texts.

ACCESS

CORPUS

CLEAR

1. Subcorpus

• Please select one or more subcorpora -

1

Democracy and Education by John Dewey.
Democracy in America, Volume 1 by Alexis de Toqueville.
Democracy in America, Volume 2 by Alexis de Toqueville.
Desert Gold. A Romance of the Border by Zane Grey.
Divina Commedia di Dante: Paradiso by Dante Alighieri.
Divina Commedia di Dante: Purgatorio by Dante Alighieri.
Dombey and Son by Charles Dickens.
~~Don Quixote by Miguel de Cervantes [Cervantes].~~
Dope by Sax Rohmer.
Dorothy and the Wizard in Oz by L. Frank Baum.

2. Confirm Choice

2

CONFIRM

Press the **CONFIRM** button, once you have made your selection.

Esempio di utilizzo

HELP

Corpus Access

W3CORPORA

PROTOTYPE F

GUTENBERG

1. Corpus Selection

CORPUS

The **Gutenberg Project**, a collection of electronic texts.

2. Search String

STRING

Press the **STRING** button, to enter a search string.

3. Submit Query

Once a search string has been entered you may proceed further.

Comments and Suggestions

COMMENTS

If you have any comments or suggestions please let us know, thank-you.

Esempio di utilizzo

HELP

Search String

ACCESS

1. String Type

CLEAR

- ☐ A regular expression
- ☐ Within a word
- ☒ Exact match

- ☐ The beginning of a word
- ☐ The end of a word

2. String

Please enter search string below:
Virgilio

3. Confirm Choice

Press the **CONFIRM** button, once you have selected a string type and string.

CONFIRM

Esempio di utilizzo

HELP

Corpus Access

W3CORPORA

PROTOTYPE F

GUTENBERG

1. Corpus Selection

The **Gutenberg Project**, a collection of electronic texts.

CORPUS

2. Search String

Virgilio

STRING

3. Submit Query

Press the **SEARCH** button to start the search ...

SEARCH

Comments and Suggestions

If you have any comments or suggestions please let us know, thank-you.

COMMENTS

Esempio di utilizzo

HELP

DISPLAY

FREQUENCY

SEARCH

OPTIONS

Frequency Screen

MATCH FREQUENCY

SUBCORPUS FREQUENCIES

LEXICAL FREQUENCIES

Match Frequency

Search String : Virgilio
String Type : Exact match.
Corpus : The Gutenberg Project, a collection of electronic texts.
Frequency : 27

Frequenze degli elementi trovati.

Esempio di utilizzo

[HELP](#)[DISPLAY](#)[FREQUENCY](#)[SEARCH](#)[OPTIONS](#)

Frequency Screen

[MATCH FREQUENCY](#)[SUBCORPUS FREQUENCIES](#)[LEXICAL FREQUENCIES](#)

Subcorpus Frequencies

Subcorpus	Frequency
Divina Commedia di Dante: Purgatorio by Dante Alighieri.	25
Divina Commedia di Dante: Paradiso by Dante Alighieri.	2
Total	27

Frequenze degli elementi trovati nei vari subcorpora.

Esempio di utilizzo

HELP

DISPLAY

FREQUENCY

SEARCH

OPTIONS

Frequency Screen

MATCH FREQUENCY

SUBCORPUS FREQUENCIES

LEXICAL FREQUENCIES

Lexical Frequencies

Lexical Items	Frequency
Virgilio	27
Total	27

Frequenze lessicali degli elementi trovati.

Esempio di utilizzo

[HELP](#)[DISPLAY](#)[FREQUENCY](#)[SEARCH](#)[OPTIONS](#)[<](#)

KWIC FRAME

[>](#)

1..10/ 27

son presenti ; mentre ch'io era a Virgilio congiunto su per lo monte che
segno . Quindi onde mosse tua donna Virgilio , quattromila trecento e due volumi di
per far colei confusa . ½ O Virgilio , Virgilio , chi ^ questa ? © , fieramente dicea ; ed el
Noi ci volgemmo s · biti , e Virgilio rend % li Æ l cenno ch Æ a
esser vivuto di l € quando visse Virgilio , assentirei un sole pi · che non
al mio uscir di bando © . Volser Virgilio a me queste parole con viso
in alto li occhi miei , ^ quel Virgilio dal qual tu togliești forte a
in s · li spiriti veloci ; quando Virgilio incominci ø : ½ Amore , acceso di virt · , sempre
quivi convien che senza lui rimagna . Virgilio ^ questi che cos Æ mi dice © , e
non so chi diceva ; per che Virgilio e Stazio e io , ristretti , oltre

Contesti in cui la parola è usata.

Espressioni regolari

HELP

Search String

ACCESS

- ☒ A regular expression
- ☐ Within a word
- ☐ Exact match

1. String Type

- ☐ The beginning of a word
- ☐ The end of a word

CLEAR

2. String

Please enter search string below.

[[Cc]ittà)|[[Cc]ittade)

3. Confirm Choice

CONFIRM

Press the **CONFIRM** button, once you have selected a string type and string.

Espressioni regolari

[HELP](#)[DISPLAY](#)[FREQUENCY](#)[SEARCH](#)[OPTIONS](#)

Frequency Screen

[MATCH FREQUENCY](#)[SUBCORPUS FREQUENCIES](#)[LEXICAL FREQUENCIES](#)

Match Frequency

Search String :	([Cc]ittà)([Cc]ittade)
String Type :	A regular expression.
Corpus :	The Gutenberg Project , a collection of electronic texts.
Frequency :	2

Espressioni regolari

HELP

DISPLAY

FREQUENCY

SEARCH

OPTIONS

<

KWIC FRAME

>

1..2/ 2

principio fu del mal de la cittade , come del vostro il cibo che
aver , che discernesse de la vera cittade almen la torre . Le leggi son

Alcuni costruttori di espressioni regolari ricorrenti

- **[stringa]**: un qualunque carattere che compaia in “stringa”.
- *****: zero o più ripetizioni dell’elemento precedente.
- **?**: zero o un’occorrenza dell’elemento che precede.
- **(exp)**: le parentesi tonde servono a raggruppare un’espressione.
- **.**: un carattere qualsiasi
- **Exp1 | Exp2**: l’espressione Exp1 oppure (in alternativa) l’espressione Exp2.