



НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
УНИВЕРСИТЕТ

Internet Studies Lab, Department of Applied
Mathematics and Business Informatics

ПРЕПРОЦЕССИНГ РУССКОЯЗЫЧНЫХ ТЕКСТОВ В




Анализ баз данных в публичном управлении
Кольцов С.Н.

Saint Petersburg, 07.09.2018

ORANGE : ПРЕПРОЦЕССИНГ

Препроцессинг состоит из следующих этапов

1. **Загрузка данных из источника данных**, например csv файл.
2. **Процедура лематизации**. Данная процедура заключается в процессе токинизации текстов.
3. **Удаление стоп слов**. Некоторые слова являются общими и при этом часто встречаются, поэтому их необходимо удалять.
4. **Визуализация текстовых данных в виде облака слов**. Наиболее частотные слова можно представить в виде облака слов, что упрощает некоторое понимание того какие темы внутри коллекции документов.



ORANGE : ПРЕПРОЦЕССИНГ

word_cloud_1.ows*

File Edit View Widget Options Help

Data

File Data Sets SQL Table Data Table

Paint Data Data Info Data Sampler Select Columns

Select Rows Rank Merge Data Concat...

Transpose Randomize Preproc... Impute

Outliers Edit Domain Python Script Image Viewer

В данном пакете можно сделать алгоритм на основе визуального программирования.

В левой части окна находится хранилище ‘виджетов’, каждый из которых отвечает за свой кусочек действий. Например, снизу приведен пример загрузки текстов из файла формата Excel.

Corpus → Data

Corpus Corpus Viewer

ORANGE : ПРЕПРОЦЕССИНГ

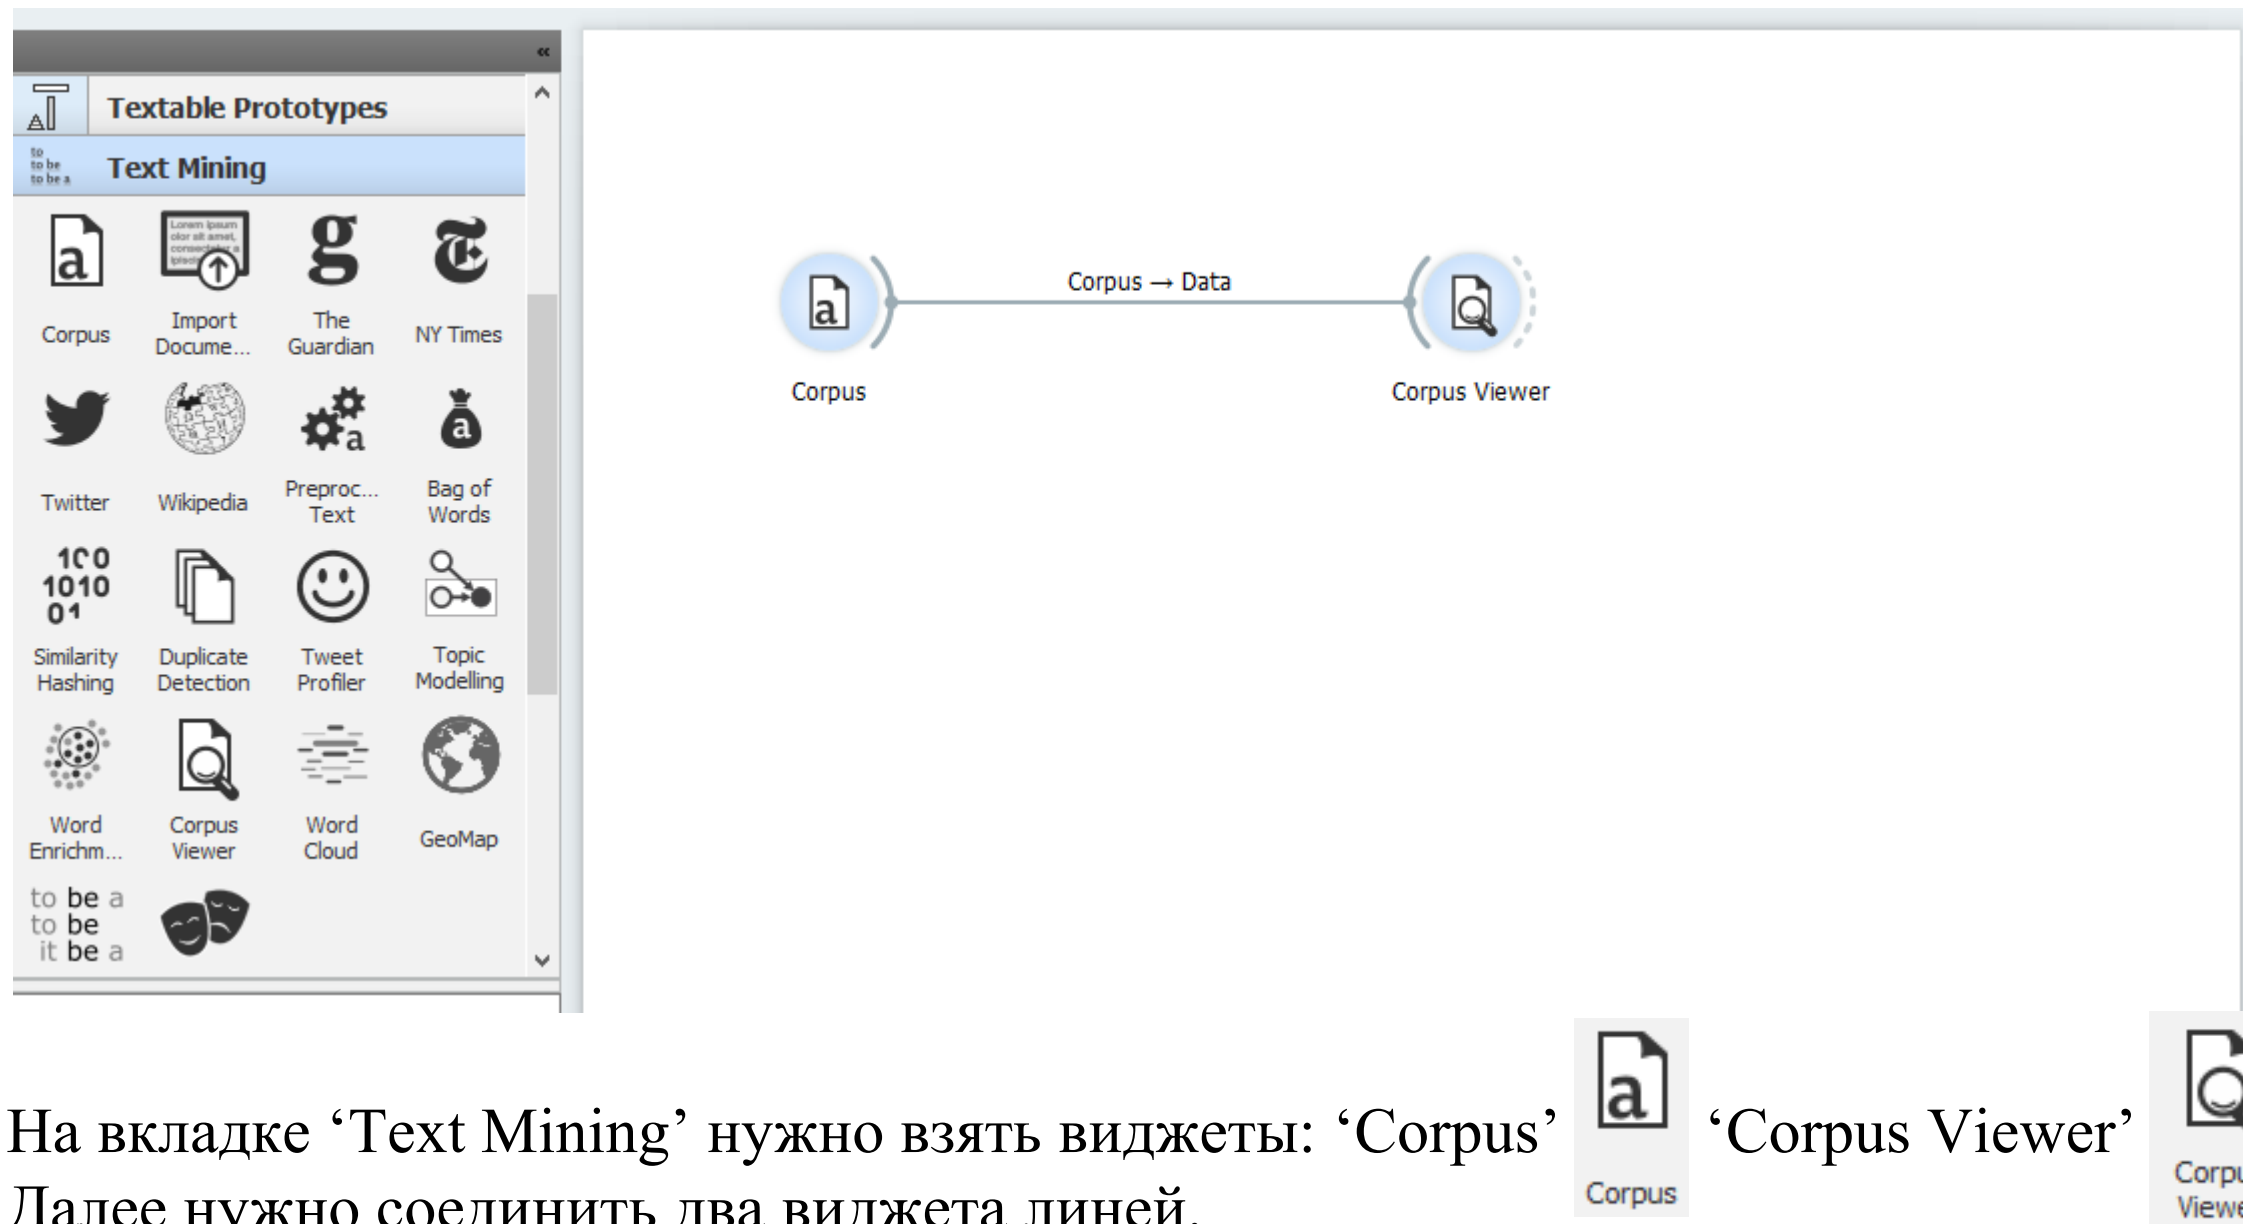
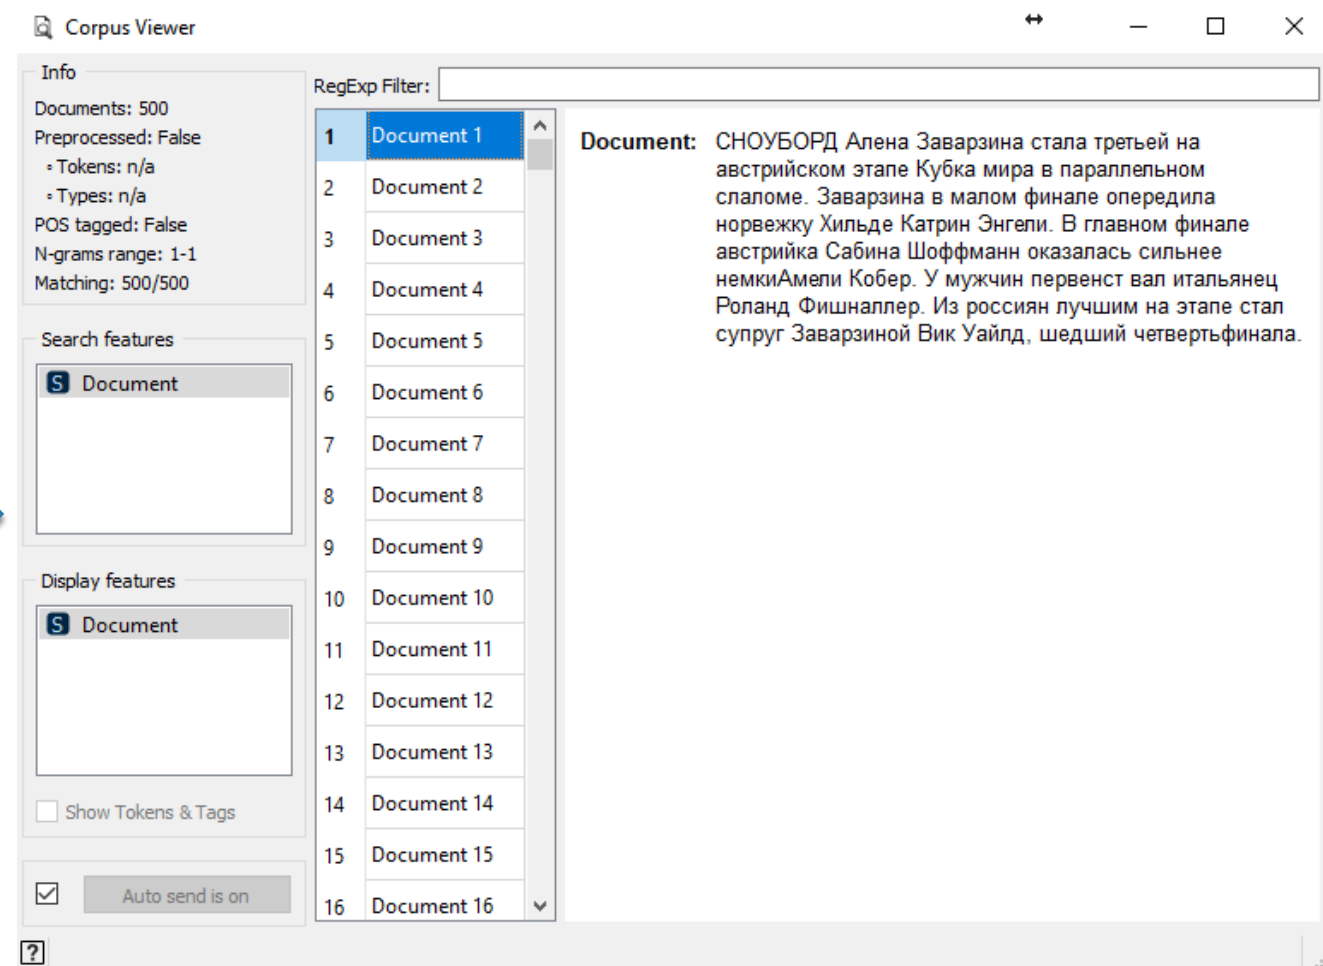
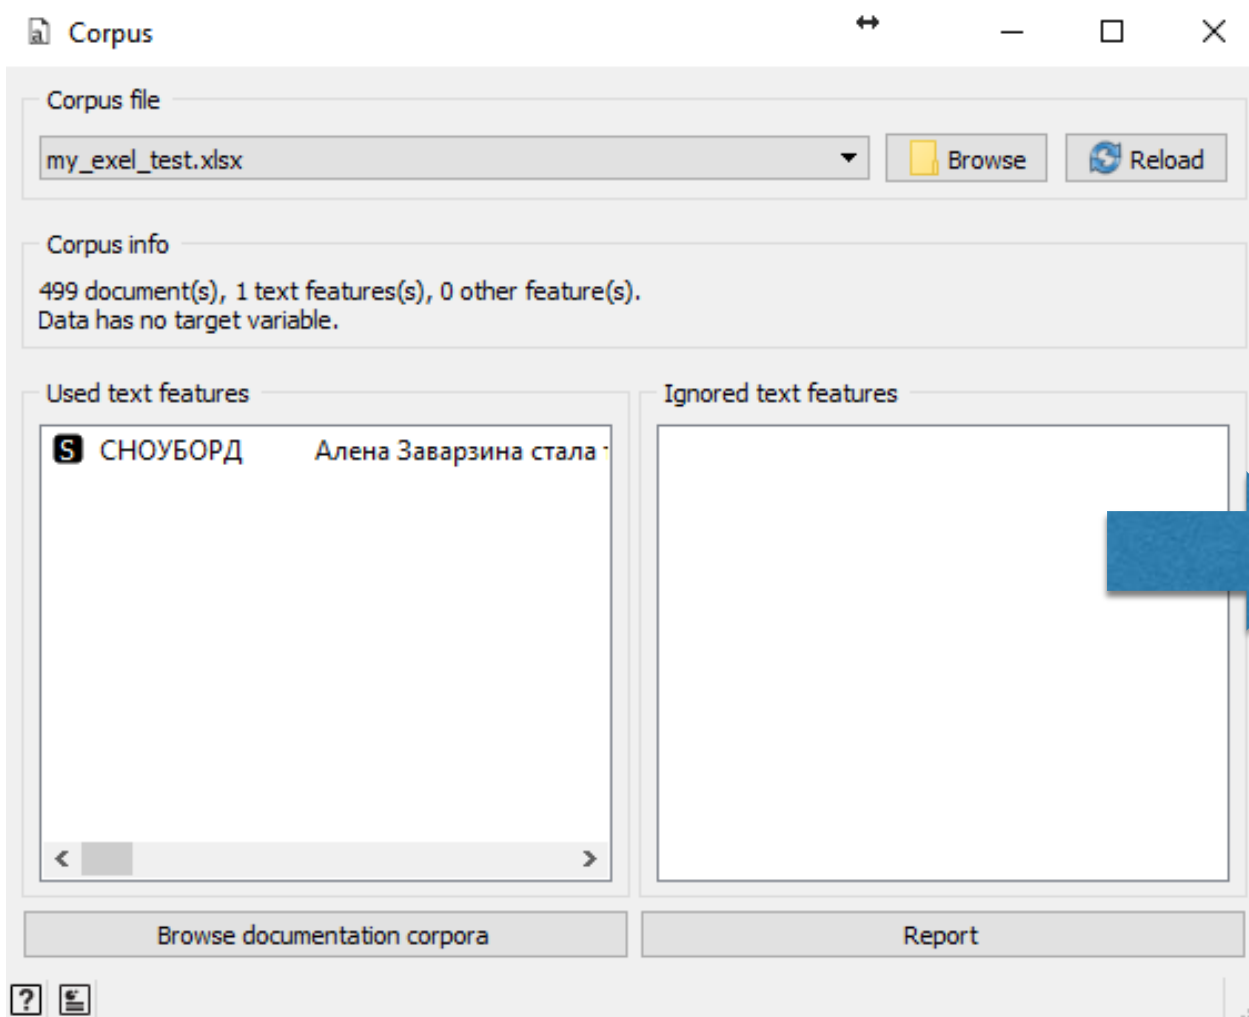


Схема загрузки готова, теперь нужно лишь указать имя файла для загрузки и просмотра.

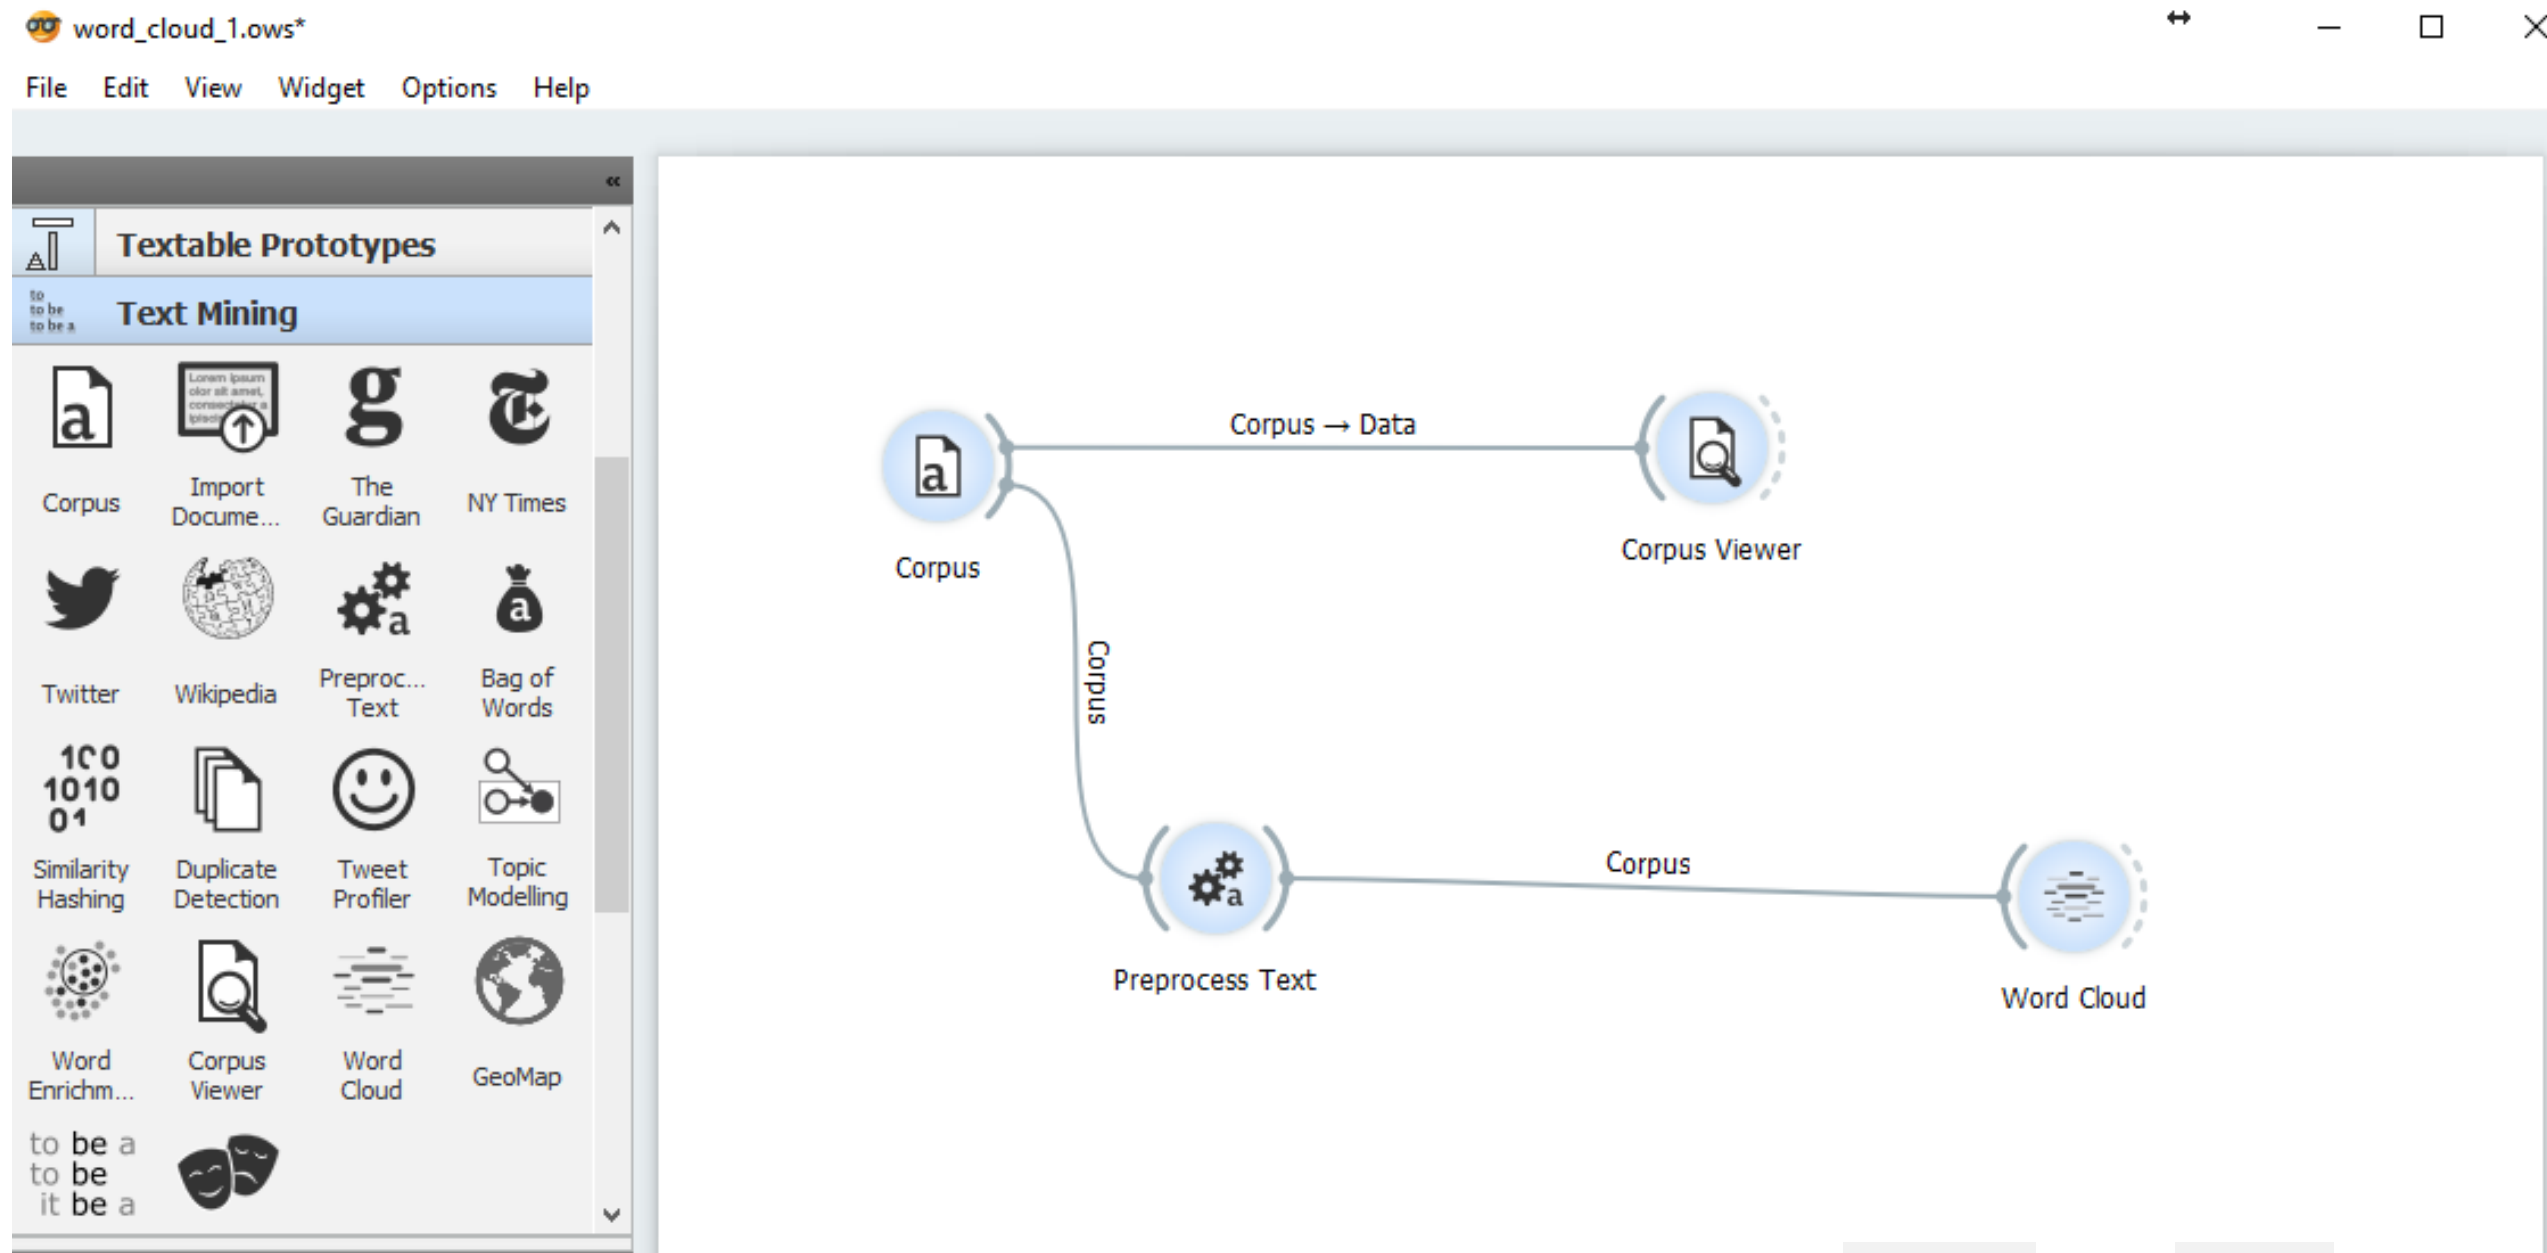
ЗАГРУЗКА И ПРОСМОТР РУССКОЯЗЫЧНЫХ ТЕКСТОВ

Для того что бы загрузить данные нужно кликнуть на виджете ‘Corpus’ и указать имя файла в формате книги Excel.



Для того что бы просмотреть результаты загрузки нужно кликнуть на виджете ‘Corpus Viewer’.


ПРЕПРОЦЕССИНГ И ОБЛАКО ЛЕМАТИЗИРОВАННЫХ СЛОВ



Для удаления стоп слов, пунктуации (и так далее), а также для построения облака слов, достаточно добавить еще два виджета:


ПРЕПРОЦЕССИНГ В ORANGE

1. Можно указать параметры препроцессинга
2. Указать файл со списком стоп слов.
3. Указать язык.


 Preprocess Text

Info


Document count: 500
Total tokens: 21303
Total types: 10017


Transformation 



☒ Lowercase ☒ Remove accents ☒ Parse html ☒ Remove urls



Tokenization 

☒ Word & Punctuation
☐ Whitespace
☐ Sentence
☐ Regexp Pattern:
☐ Tweet

Normalization [disabled] 

Filtering 


☒ Stopwords  


☒ Lexicon  

☒ Regexp

☐ Document frequency

☐ Most frequent tokens


N-grams Range [disabled] 

POS Tagger [disabled] 

☒ Commit Automatically



SNOWBALL STEMMER

Normalization 


☐ Porter Stemmer

☒ Snowball Stemmer

☐ WordNet Lemmatizer

Language: Russian

Данный стеммер просто
обрезает концы слов, то
есть не годится для
русского языка





НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
УНИВЕРСИТЕТ

<https://linis.hse.ru/>

Phone: +7 (911) 981 9165

Email: skoltsov@hse.ru