



Міжнародна науково-технічна конференція
**ІНТЕЛЕКТУАЛЬНІ ТЕХНОЛОГІЇ ЛІНГВІСТИЧНОГО
АНАЛІЗУ**

22-23 жовтня 2013 року

**ПЕРСПЕКТИВЫ МЕТОДА
"ГРАФОВ ВИДИМОСТИ"**

В КОМПЬЮТЕРНОЙ ЛИНГВИСТИКЕ

Д.В. ЛАНДЭ, д.т.н.,
А.А. СНАРСКИЙ, д.ф.-м.н., профессор,
Інститут проблем регистрации информации НАН
Украины, Киев

Киев, 22 октября 2013 г.



Аннотация

Предлагается методика создания компактифицированного графа горизонтальной видимости. Исследованы свойства таких сетей слов, показано, что они являются безмасштабными, а также, что среди узлов с наибольшими степенями имеются слова, определяющие не только структуру связности текста, но и его информационную структуру.



Актуальнosть

Наряду с последовательным, «линейным» анализом текстов, построение сетей, узлами которых являются их элементы – фрагменты естественного языка, позволяет выявлять структурные элементы текста, без которых он теряет свою связность. При этом актуальной является задача определения того, какие из важных структурных элементов оказываются также информационно-значимыми, определяющими информационную структуру текста. Такие элементы могут использоваться также для идентификации еще не достаточно четко теоретически определенных компонент текста, таких как коллокации, сверхфразовые единства, например, при поиске подобных фрагментов в различных текстах.



Сети слов

Первым шагом при применении теории сложных сетей к анализу текста является представление этого текста в виде совокупности узлов и связей, построение сети языка (*Language Network*).

Существуют различные способы интерпретации узлов и связей, что приводит, соответственно, к различным представлениям сети языка.

Узлы могут быть соединены между собой, если соответствующие им слова стоят рядом в тексте, принадлежат одному предложению, соединены синтаксически или семантически.



Простейшие сети слов

- **L-пространство.** Связываются соседние слова, которые принадлежат одному предложению. Количество соседей для каждого слова (окно слова) определяется радиусом взаимодействия R , чаще всего рассматривается случай $R = 1$.
- В-пространство.** Рассматриваются узлы двух видов, соответствующие предложениям и словам, которые им принадлежат.
- Р-пространство.** Все слова, которые принадлежат одному предложению, связываются между собой.
- С-пространство.** Предложения связываются между собой, если в них употреблены одинаковые слова.



Из рядов - графы

На стыке теорий цифровой обработки сигналов (Digital Signal Processing) и сложных сетей (Complex Network) предложено несколько методов построения сетей на основе временных рядов, среди которых можно назвать несколько методов построения графов видимости, в частности, так называемый граф горизонтальной видимости (Horizontal Visibility Graph – HVG). Эти подходы позволяют строить сетевые структуры также и на основании текстов, в которых отдельным словам или словосочетаниям некоторым специальным образом поставлены в соответствие некоторые весовые значения.



Весовые оценки слов

В качестве функции, ставящей в соответствие слову из текста число, можно рассматривать, например, порядковый номер уникального слова в тексте, длину слова, «вес» слов в текстах, общепринятую оценку TFIDF или ее варианты, а также другие весовые оценки, в частности, статистические дисперсионные.



TFIDF

В качестве весовой оценки из полного текста, состоящего из слов, текст разбивается на фрагменты, содержащие заданное количество **N** слов **M** (например, **M = 500**). Затем для каждого слова **i**, входящего в текст, подсчитывается количество фрагментов **df(i)**, в которые это слово входит, а также общее количество вхождений данного слова **i** в текст – **n(i)**. После этого рассчитывается среднее значение весовой оценки каждого слова в тексте, близкое по идеологии к классическому TFIDF:

$$tfidf(i) = \frac{n(i)}{N} \log \left(\frac{N}{M \times df(i)} \right)$$




Дисперсионная оценка



Дисперсионная σ_A оценка для некоторого слова A из текста рассчитывается как


$$\sigma_A = \frac{\sqrt{\langle \Delta A^2 \rangle - \langle \Delta A \rangle^2}}{\langle \Delta A \rangle},$$

где: $\langle \Delta A \rangle$ – среднее расстояние (в словах) между появлениями слова A в тексте; : $\langle \Delta A^2 \rangle$ – среднее квадрата расстояния между появлениями слова A в тексте.




Формирование графа горизонтальной видимости





Этапы построения КГГВ



Компактифицированный граф
горизонтальной видимости



Основы оценки методов

Если обозначить Ψ - множество из N различных слов из «стоп-словаря» языка, а Λ - множество слов, соответствующих наиболее весомым узлам КГГВ, то множество $\Omega = \Lambda \setminus \Psi$ соответствует информативным словам, имеющим, кроме того, важное значение и для связности текста.




Наиболее весомые узлы КГГВ

А. Дюма, «Три мушкетера»


14053 Д'АРТАНЬЯН
9347 МИЛЕДИ
9057 АТОС
4128 АРАМИС
3945 БОНАСЬЕ
3878 ПОРТОС
3755 ДЕ
3038 ФЕЛЬТОН
2599 КАРДИНАЛ
2384 СУДАРЬ
2248 ПЛАНШЕ
1940 ТРЕВИЛЬ
1689 ВЕЛИЧЕСТВО
1585 ПИСЬМО
1542 КОРОЛЬ
1400 ГЕРЦОГ
1342 ГОСПОДИН
1310 КЭТТИ

1301 СУДАРЫНЯ
1248 ЖЕНЩИНА
1229 ЛА
1128 КОРОЛЕВА
1033 ВИНТЕР
925 ГОСПОДА
898 ГРИМО
891 ЛОШАДЬ
888 МОЛОДОЙ
852 СВЕТЛОСТЬ
738 ДРУЗЕЙ
728 ЧЕЛОВЕКА
723 РУКИ
721 ХОЗЯИН
708 ДЕЛО
683 ЧАСОВ
669 ПИСТОЛЕЙ
657 МИЛОРД



Визуализация КГГВ

А. Дюма, «Три мушкетера»






Наиболее весомые узлы КГГВ


Дж. Толкиен, «Хоббит, или Туда и обратно»

- | | |
|---------------|----------------|
| 5478 БИЛЬБО | 382 ФИЛИ |
| 2227 ГЭНДАЛЬФ | 365 ДВЕРИ |
| 1879 ТОРИН | 334 БЕРТ |
| 1476 ГНОМ | 287 ПАУКИ |
| 1221 ГОБЛИН | 284 ГЛАЗА |
| 1009 ГОЛЛУМ | 282 БОЧКИ |
| 800 ЭЛЬФЫ | 277 ОЗЕРА |
| 777 ДРАКОН | 272 ГОР |
| 738 ПОНИ | 263 ГОРОД |
| 707 БЭРД | 256 КОРОЛЯ |
| 702 ГОРЫ | 254 БОМБУР |
| 617 КОРОЛЬ | 252 ЗОЛОТО |
| 530 ХОББИТ | 244 ПАУК |
| 509 БЕОРН | 242 ГОРЕ |
| 483 КОЛЬЦО | 238 СМОГА |
| 453 ВОЛШЕБНИК | 235 БУРГОМИСТР |
| 432 ЛЕС | 228 АРКЕНСТОН |
| 409 БАЛИН | 224 СВЕТ |



Визуализация КГГВ

Дж. Толкиен, «Хоббит, или Туда и обратно»





Некоторые результаты

- Предложен алгоритм построения компактифицированного графа горизонтальной видимости (КГГВ).
- На основе последовательности дисперсионных оценок слов текста и КГГВ, построены сети слов различных текстов.
- Для литературных текстов среди узлов соответствующих КГГВ с наибольшими степенями присутствуют слова, не только обеспечивающие связность структуры текста, но и определяющие его информационную структуру, отражают семантику литературных произведений.
- Алгоритм определения веса слов, базирующийся на дисперсионной оценке оказался более эффективным для определения информационно-значимых слов, играющих важное значение для структурной связности в литературных текстах, чем алгоритм TFIDF.



Перспективы

- Изучение свойства выявленных одновременно информационно и структурно важных лексических единиц как опорных слов для различных текстовых жанров, документов, представленных на разных языках. Это позволит:
 - Формировать «более осмысленные» информационные портреты текстов;
 - Более качественно выполнять автоматическое рефериование текстов;
 - Формировать цепочки подобных документов, объединять тематические сюжеты, используя выявленные слова в качестве дескрипторов;
 - Выявлять возможное содержательное дублирование документов, представленных на различных языках (необходимо дальнейшее исследование инвариантности опорных слов, для исходных текстов и их переводов);
 - Составлять словари опорных слов, формировать тезаурусы и онтологии предметных областей.



Міжнародна науково-технічна конференція
**ІНТЕЛЕКТУАЛЬНІ ТЕХНОЛОГІЇ ЛІНГВІСТИЧНОГО
АНАЛІЗУ**

22-23 жовтня 2013 року

Спасибо за внимание!

Д.В. ЛАНДЭ

dwlande@gmail.com