



Методы анализа текста в R

Алексей Горгадзе
Анастасия Кузнецова

NET-RESEARCH.NET

Чистка данных

```
library(tm); library(tidytext)
```

```
text <- gsub("[^[:alnum:]]", " ", text)
```

```
text <- gsub("[a-zA-Z0-9]+", "", text)
```

```
text <- tolower(corp)
```

```
text <- removeNumbers(text)
```

```
text <- removePunctuation(text)
```

```
text <- removeWords(text, stopwords("russian"))
```

```
text <- removeWords(text,  
stoplist)
```

В стоп слова входят
(stoplist):

- слишком частотные
- слишком редкие
- слишком короткие
- не существительные
- имена собственные

Лемматизация

Приведение словоформы к лемме (к инфинитиву)

MyStem (Яндекс) - производит морфологический анализ текста на русском языке

`text.tmp <- system2("mystem", c("-c", "-I", "-d"), input=docs$text, stdout=TRUE)` (должен быть установлен MyStem)

кошками -> кошка

Стемминг (урезание слова до основы):

кошками -> кошк

Форматы текстовых данных

```
corpus1 <- Corpus(VectorSource(text), readerControl=list(language='ru'))
```

```
tdm.matrix <- TermDocumentMatrix(corpus1) / dtm.matrix <- DocumentTermMatrix(corpus1)
```

```
words_matrix <- as.matrix(tdm.matrix)
```

term-document matrix



	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
ад	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0
ангел	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
бояться	1	0	0	0	0	0	0	0	0	0	0	0	2	0	0
внутри	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
возникать	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
вопрос	3	0	0	0	0	0	0	1	0	0	0	0	3	0	0
впечатление	1	0	0	0	0	0	0	0	1	2	0	0	0	0	0
второй	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0
вырастать	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
герой	1	0	0	0	0	3	0	2	1	2	1	0	0	0	0
голова	1	0	1	0	0	0	0	0	0	1	0	0	0	0	0
грязь	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Name	Type	Value
wCorpus	list [2392] (S3: SimpleCorpus, List of length 2392	
1	list [2] (S3: PlainTextDocumer	List of length 2
content	character [1]	'какой-то пустота образовываться внутри я после завершени...
meta	list [7] (S3: TextDocumentMet	List of length 7
author	character [0]	
datetimestamp	list [1] (S3: POSIXlt, POSIXt)	List of length 1
[[1]]	double [1]	31.43707
description	character [0]	
heading	character [0]	
id	character [1]	'1'
language	character [1]	'ru'
origin	character [0]	
2	list [2] (S3: PlainTextDocumer	List of length 2
3	list [2] (S3: PlainTextDocumer	List of length 2

Частотность слов

```
words_freq <- sort(rowSums(words_matrix), decreasing=TRUE)
```

```
words_freq <- data.frame(freq = words_freq, word = names(words_freq))
```

Облака слов



```
wordcloud(words = words_freq$word, freq =  
words_freq$freq, scale=c(2,.2), min.freq = 5,  
max.words=Inf, random.order=FALSE, rot.per=0.1,  
ordered.colors=FALSE,  
random.color=TRUE,colors=pa12)
```

14:45 - 15:59

жалко ужасно соболезную сенная россия
закрыты соболезнования удельной
близким станции родным уроды
какие рамки просто откуда шоке
фото закрыли ого просто откуда шоке
правда народ говорят новости почему
вилия калец боже **метро**
также **ужас** господи
жесть ппц назад россии
спасибо людям
погибших
кошмар взрывы
сенной
смотри кровь
точно знаю людей время курсе жуть
горе слово девятым взрыва взорвали
пострадавших домой восстания
минут пострадавшим погибло терракт

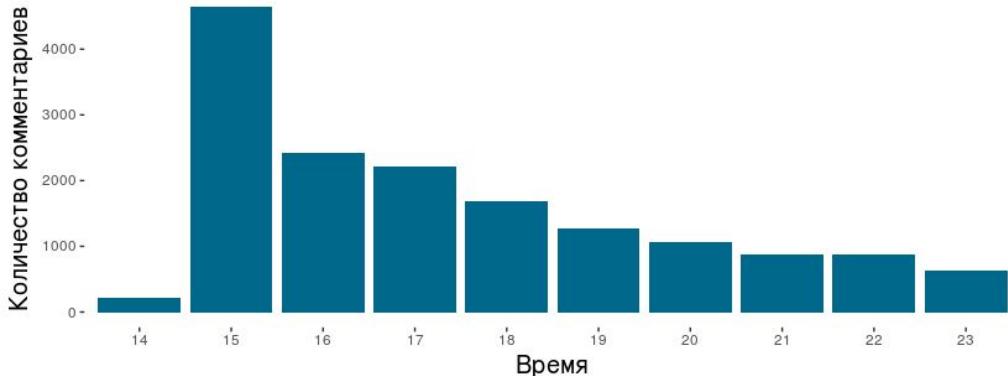
16:00 - 18:59

дай держитесь пострадавших поеду бред
могут друг соболезнования инфа
близким просто купчино фото
тех станции ужас пишите ботов
час бог будут взрывы погибших питер
просвета таких едет места еду завтра
сенней расширь другу зсд мчс
мои силы пожалуйста могу кровь
близких говорят людям страшно
часа родным стороны час
взрыва людьми домой кому ребята
знаю санкт спасибо такси либо
друзья город день минут спасибо
минут сенная соболезнуую хватит откуда

19:00 - 21:59

станции нарской девятым северу автова
почему список пострадавших держитесь
такие страшно пожалуйста регистрация
нико линии соболезнования довезу
мес движение просто родным время
большевиков г телет завтра города
утром ветеранов спб пон
хотя речи тел люди места пишите год
минут бесплатно видеодома
метро едем
сторону домой могу
мои кому вами
говорят спасибо едет года
больница крови еду людей тех
вместе примерно купчино дыбенко
которые восстания отделение дома
работать сенная переливания близким парнаса
проспекта соболезнуую открыли откуда

Количество комментариев по часам



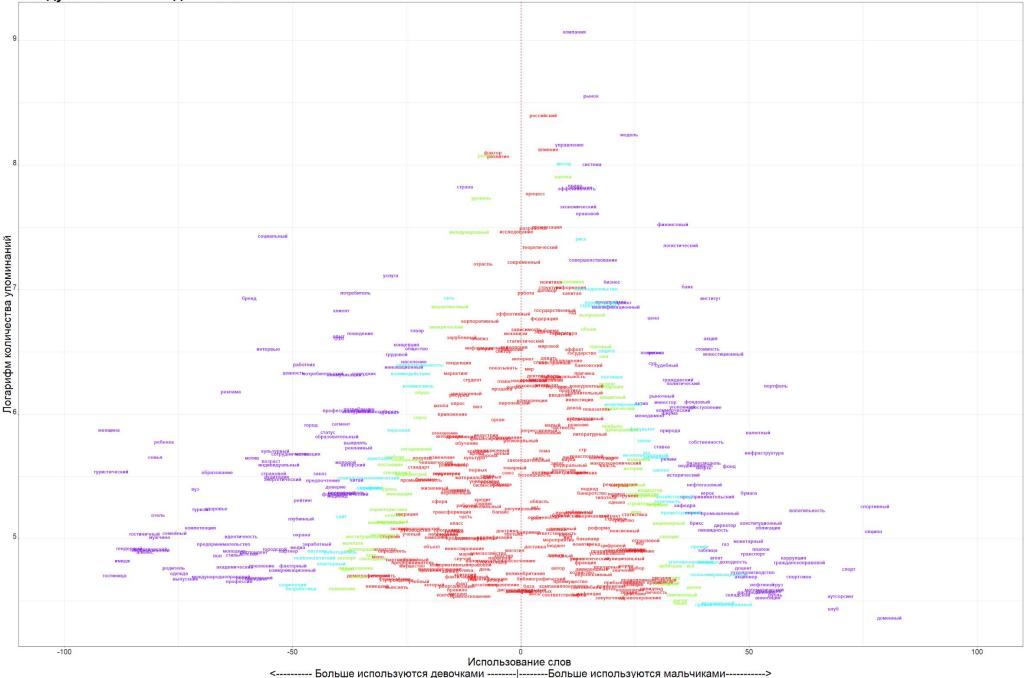
21:59 - 23:37

сил полицию жить которые нужно цель мать
бесплатно рбк соболезнования ужас мать
людям страшно этих примерно взрывы топи
домой примерно взрывы топи
дай быту погибших завтра людям никто
теракта станции родных маму вместе
будем сумку лет
спасибо людям просто фото главное бог
далние самое время просто питер тех
места года мог спасибо нам день ночь
жизни могла спасибо какое народ города
сторону пострадавших неизвестная видео входу
близким откуда мчс

Сравнение частотностей

```
wordsCompare$prop <- wordsCompare$Male/sum(wordsCompare$Male)
wordsCompare$prop2 <- wordsCompare$Female/sum(wordsCompare$Female)
```

Сравнение используемых слов на факультетах
экономики, социологии, юриспруденции и менеджмента
Между мальчиками и девочками



```
# Broke down the z score formula a little to understand how it worked
a <- wordsCompare$prop
b <- wordsCompare$prop2
c <- wordsCompare$Male
d <- wordsCompare$Female
e <- sum(c)
f <- sum(d)

# z score formula - adds column for z scores
wordsCompare$z <- (a - b) / ((sqrt((sum(c) * a) + (sum(d) * b)) / (sum(c) +
sum(d))) * (1 - ((sum(c) * a) + (sum(d) * b)) / (sum(c) +
sum(d)))) * (sqrt((sum(c) + sum(d)) / (sum(c) *
sum(d)))))

# calculate percentage reduction:
wordsCompare$dif1 <- -100 * (1 - wordsCompare$prop/wordsCompare$prop2)
# calculate percentage increase
wordsCompare$dif2 <- 100 * (1 - wordsCompare$prop2/wordsCompare$prop)

-----
require(ggplot2)

png("eco_def_m_f_words_full_size_byDif.png", width=3000,height=1500)
ggplot(wordsCompare3, aes(dif, log(abs(Male + Female)), size =
1,label=Row.names, colour = z2))+
  scale_colour_gradientn(name="Z Score", colours=c("#80FF00FF",
"#00FFFFFF", "#800000FF")) +
  geom_text(fontface = 2, alpha = .8) +
  #scale_size(range = c(3, 12)) +
  ylab("Логарифм от количества упоминаний") +
  xlab("Использование слов \n<-----Больше используются  
девушками -----|-----Больше используются мальчиками----->")+
  geom_vline(xintercept=0, colour = "red", linetype=2)+  

  theme_bw() #theme(legend.position = "none") +
  ggtitle("Сравнение используемых слов на факультете экономики  
\\pmежду мальчиками и девочками")
dev.off()
```

Коллокации

library(quanteda)

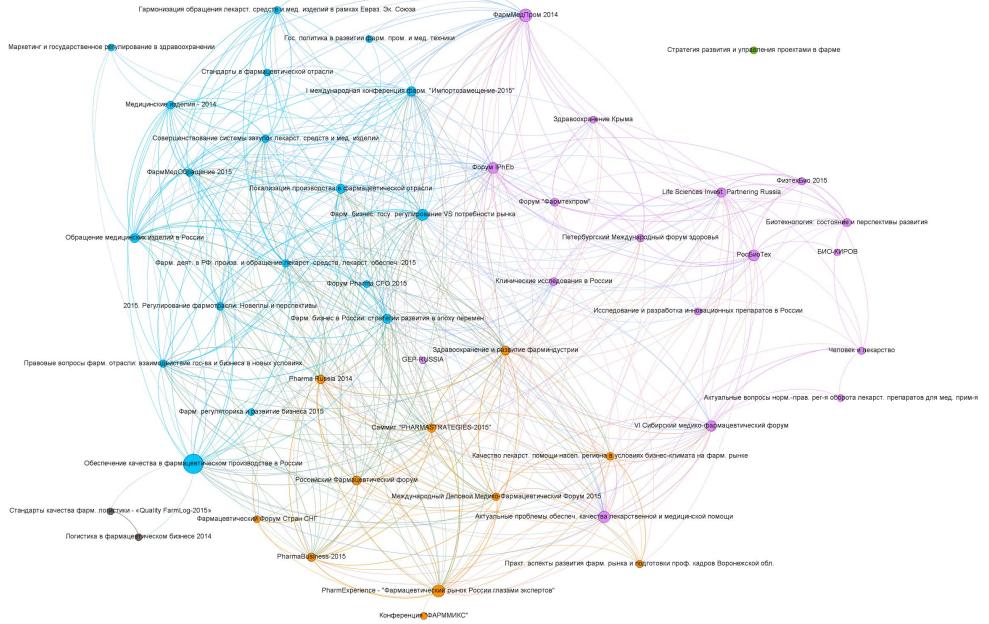
collocations <-

textstat_collocations(text, size = 2:3)



	collocation	count	length	lambda	z
1	главный герой	51	2	5.594665	26.268972
2	друг друг	36	2	5.457287	23.975265
3	самый дело	30	2	4.817666	20.631267
9	очень понравиться	21	2	3.518055	14.267273
4	главный героиня	19	2	6.262405	18.490280
8	год назад	15	2	6.308578	14.505164
5	сей пора	13	2	7.027718	16.648241

LSA - семантическая близость слов



library(lsa)

```
tdm<-as.TermDocumentMatrix(dtmw)
```

```
lsa_space<-lsa(tdm, dims=dimcalc_share())
```

```
lsa_word_space<-lsa(dtmw, dims=dimcalc_share())
```

```
tdm_lsa<-as.textmatrix(lsa_space)
```

```
tdm_word_lsa<-as.textmatrix(lsa_word_space)
```

```
tdm_lsa[1:5,1:5] # что присвоено "tdm_lsa" (какое-то значение)
```

```
as.matrix(tdm)[1:5,1:5]
```

```
t.locs<-lsa_space$tk %*% diag(lsa_space$sk)
```

```
plot(t.locs,type="n")
```

```
text(t.locs, labels=rownames(lsa_space$tk))
```

```
lsa_space2<-lsa(tdm, dims=2)
```

```
t2.locs<-lsa_space2$tk %*% diag(lsa_space2$sk)
```

```
plot(t2.locs,type="n")
```

```
text(t2.locs, labels=rownames(lsa_space2$tk))
```

```
lsa.distances<-cosine(tdm_lsa) # косинусное расстояние между текстами в LSA-пространстве
```

```
rownames(lsa.distances) <- farm$Name
```

```
colnames(lsa.distances) <- farm$Name
```

```
lsa.distances[upper.tri(lsa.distances)] <- NA
```

```
diag(lsa.distances)=NA
```

```
lsa.matrix <- melt(lsa.distances)
```

```
colnames(lsa.matrix) <- c("Source", "Target", "Weight")
```

```
lsa.matrix<-lsa.matrix[lsa.matrix$Weight > 0, ]
```

```
lsa.matrix<-lsa.matrix[!(is.na(lsa.matrix$Weight)), ]
```

```
lsa.matrix$Weight2 <- lsa.matrix$Weight
```

```
lsa.matrix$type <- "Undirected"
```

```
write.csv(lsa.matrix, "graph_farmo_lsa.csv")
```

```
View(order(lsa.matrix$Weight))
```

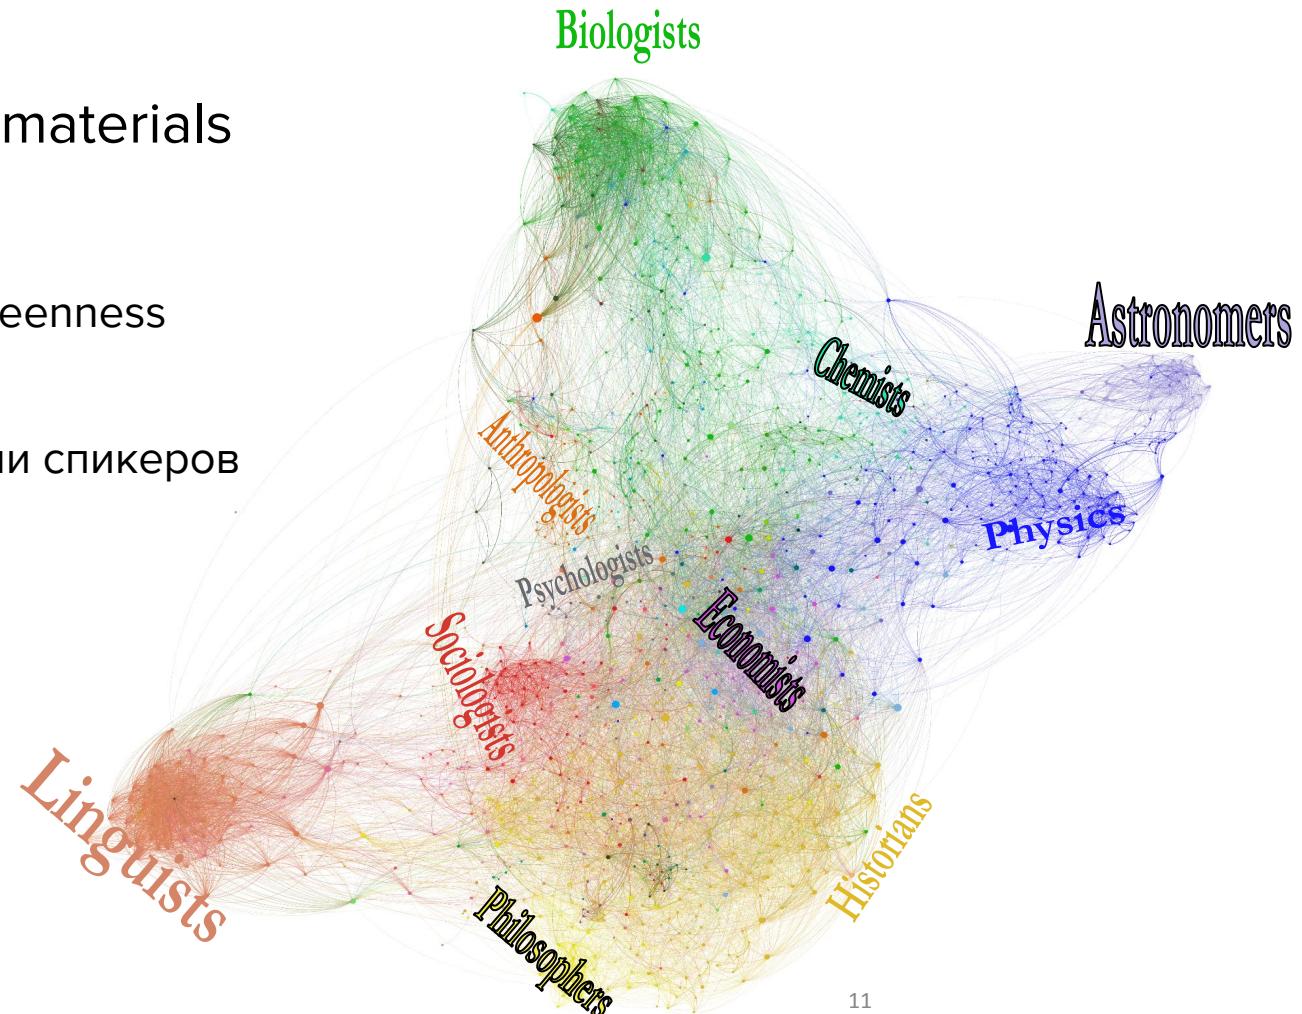
```
write.csv(labels_farma, "labels_farma.csv")
```

LSA - PostNauka materials

Размер узлов - Betweenness Centrality

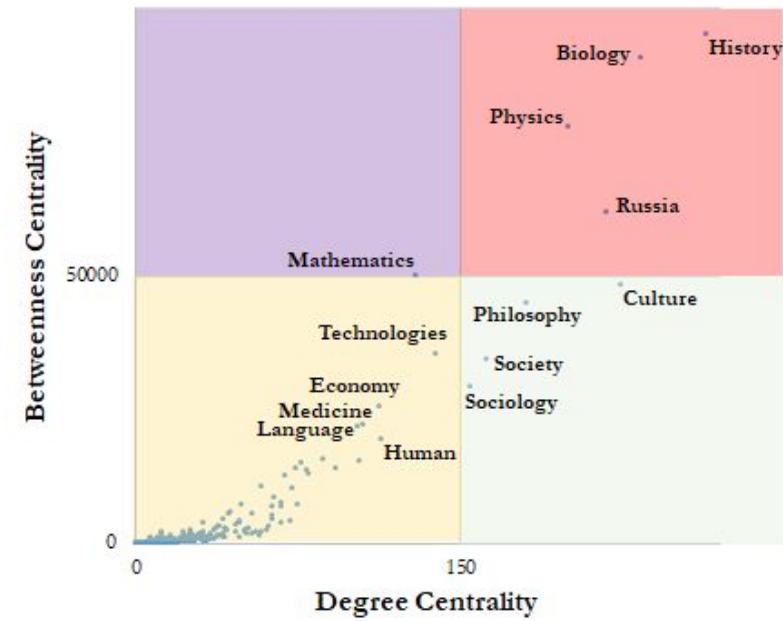
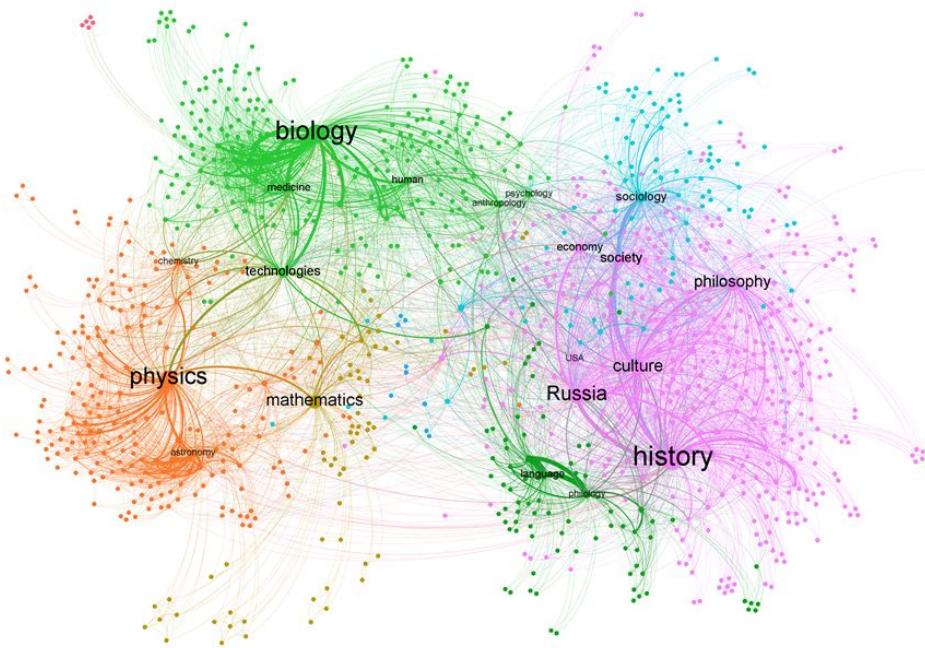
Цвет - специализации спикеров

Связь - LSA метрики



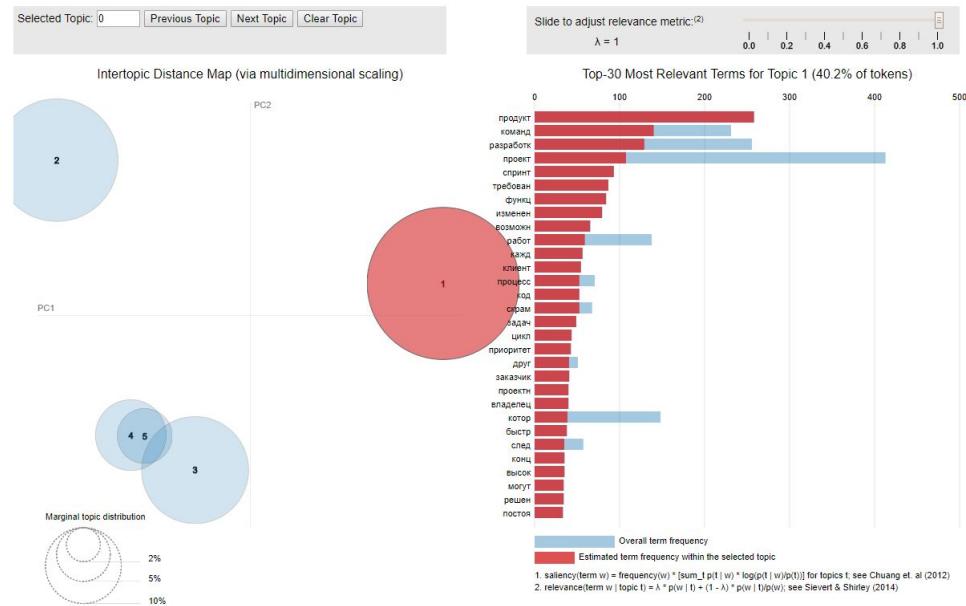
Key-words centralization structure

LSA - PostNauka materials



LDA — к каким темам относится документ

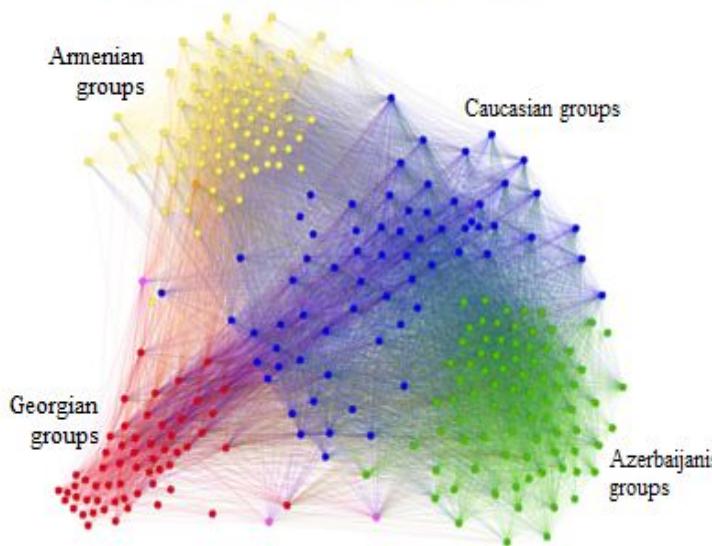
```
library(mallet)
mallet.instances <- mallet.import(id.array = tb$Название.раздела, text.array = corp, stoplist.file = "./data/stopwords.txt")
## настраиваем параметры модели и загружаем данные
topic.model <- MalletLDA(num.topics=5) # количество тем
topic.model$loadDocuments(mallet.instances)
topic.model$setAlphaOptimization(20, 50) # оптимизация гиперпараметров
## собираем статистику: словарь и частотность
vocabulary <- topic.model$getVocabulary() # словарь корпуса
word.freqs <- mallet.word.freqs(topic.model) # таблица частотности слов
## вершина частотного списка (по документной частоте)
head(word.freqs[order(word.freqs$doc.freq, decreasing=T),],30)
## параметр — количество итераций
topic.model$train(1000)
## выбор наилучшей темы для каждого токена
topic.model$maximize(10)
### LDA: выгрузка результатов
## таблица распределения тем по документам
doc.topics <- mallet.doc.topics(topic.model, smoothed=TRUE, normalized=TRUE)
## таблица распределения слов по темам
topic.words <- mallet.topic.words(topic.model, smoothed=TRUE, normalized=TRUE)
## метки для тем (по трем главным словам)
topic.labels <- mallet.topic.labels(topic.model, topic.words, 5)
```



[Ссылка на интерактивный график](#)

LDA: этнические группы в ВК

Network of groups based on overlapping membership (Jaccard index)



Family values and gender stereotypes

