

# Interactive Coding of Responses to Open-Ended Questions in Russian

Nikita Senderovich   Archil Maysuradze

Faculty of Computational Mathematics and Cybernetics,  
Lomonosov Moscow State University

KESW, 2015

# Agenda

- 1 The Task of Coding Open-Ended Questions
- 2 Concept of the Interactive System
- 3 Data Processing Steps
- 4 The Developed System

# Types of Questions in Surveys

- closed-ended questions — choice from fixed set of answers
- **open-ended questions** — response in respondent's own words
- hybrid questions:

## Гибридный вопрос

Какими наиболее существенными негативными последствиями для города Сочи чревато проведение Зимних Олимпийских Игр 2014 г? (выбрать один из вариантов)

- Удорожание жизни
- Уплотнение застройки
- Дополнительная нагрузка на городской бюджет
- Истребление редких видов растений и животных
- Другое

*Введите свой вариант ответа*

# General Approach to Coding Task

- extraction of ideas from the answers
- creation of the codebook
- assigning one or more codes to each answer

Example of Coding Result:

**Что из того, о чём говорил Д. Медведев на пресс-конференции, Вам больше всего запомнилось и понравилось?**

<b>Молодёжная политика</b>	«наша молодёжь будет жить лучше»; «о школьниках, студентах»; «Медведев болеет за молодёжь, даёт им работу»; «уделял внимание молодёжи»
<b>Отмена техосмотра</b>	«про техосмотр»; «упрощение системы прохождения осмотров автомобилей»; «он и сказал, что техосмотр теперь будут оформлять не в ГАИ, а при ОСАГО»
<b>Инновации, модернизация</b>	«усовершенствование производства, инновации»; «модернизация»; «надо продолжать процессы модернизации в экономике и политике»; «развитие науки»
<b>Борьба с коррупцией</b>	«о коррупции в рядах чиновников»; «о борьбе с коррупцией»; «реформы надо продолжать и жёстче бороться с коррупцией»; «коррупция»

## Typical Process:

- senior analyst creates the codebook
- group of analysts performs the coding

## Problems:

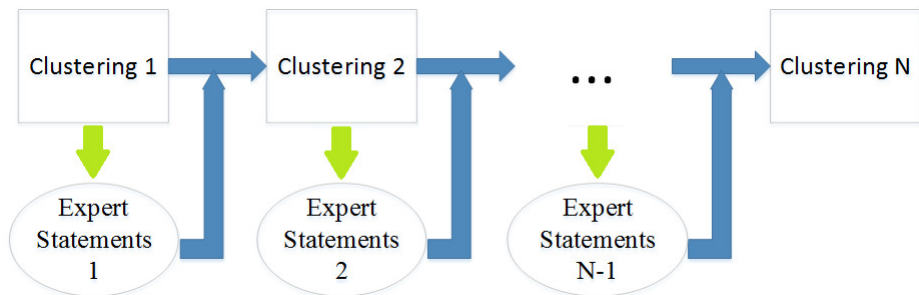
- laboriousness
  - consistent codebook modification
  - intercoder agreements
- subjectivity

No proven industry standard for automated coding exists.

Propose and study the coding process with the following properties:

- work in group
- coding result consistent with opinion of members of the group
- inductive approach to building coding scheme

# Interactive Clustering



# Domain-Oriented Set of User Statements

- 1 select the subset of responses
- 2 attach selected subset to existing cluster
- 3 attach selected subset to new cluster
- 4 detach responses of selected subset from clusters they are attached to
- 5 withdraw selected subset from consideration
- 6 complete the formation of cluster
- 7 continue the formation of cluster
- 8 remove the cluster

## Theorem

*Statements 1, 3, 5, 8 allow to achieve arbitrary clustering.*



- group of analysts make statements through web-interface in real time

# Cooperative Workflow

- group of analysts make statements through web-interface in real time
- consistent current state is presented at all times

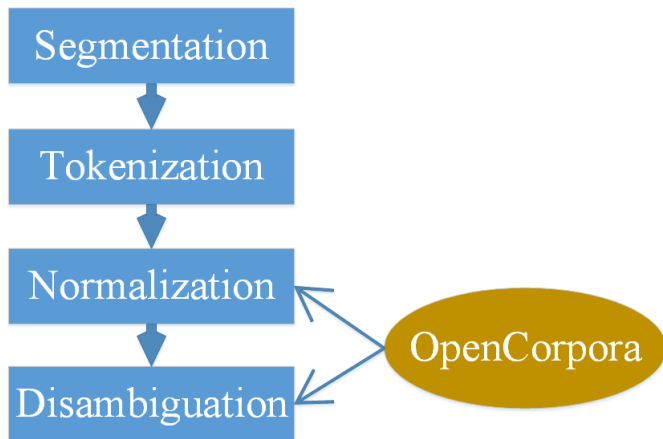
# Cooperative Workflow

- group of analysts make statements through web-interface in real time
- consistent current state is presented at all times
- the result is validated online

# Cooperative Workflow

- group of analysts make statements through web-interface in real time
- consistent current state is presented at all times
- the result is validated online
- matters of opinion are detected and agreement is achieved

- group of analysts make statements through web-interface in real time
- consistent current state is presented at all times
- the result is validated online
- matters of opinion are detected and agreement is achieved
- objectivity is increasing



# Vector Space Model

$W$  — dictionary of all terms

$D$  — set of responses

$n_{dw}$  — number of occurrences of term  $w$  in document  $d$

$d = [f_1^d, \dots, f_{|W|}^d]^T$ , where  $f_w^d = [n_{dw} > 0]$ ,  $d \in \mathbb{R}_+^{|W|}$


Standard similarity function — cosine measure:

$$s(u, v) = (u, v), \quad \|u\| = \|v\| = 1.$$

# Source Data Sparseness Problem

Part of Typical Term-Document Matrix:

□ **Word presence**      ■ **Word absence**





# Source Data Sparseness Problem

**Problem:** lack of common context information

**Sources of additional information:**

- semantic graphs and nets
- expert opinion

**Semantic smoothing method:**

Russian Thesaurus (RuThes)  $\rightarrow$  semantic proximity matrix  $P \rightarrow$

$$\text{similarity function } s'(u, v) = \frac{(Lu, Lv)}{\|Lu\| \|Lv\|}, \quad L^T L = P \rightarrow$$

distance function  $d(u, v)$

- **hierarchical algorithms** (agglomerative and divisive):

- Single linkage clustering:  $d(C_i, C_j) = \min_{x \in C_i, y \in C_j} d(x, y)$

- UPGMA clustering:  $d(C_i, C_j) = \frac{1}{|C_i||C_j|} \sum_{x \in C_i} \sum_{y \in C_j} d(x, y)$

- DIANA clustering

- **spherical k-Means**

- applying smoothing:  $x_j = \frac{P_{x_j}}{\|P_{x_j}\|}$

- formulating an optimization problem:

$$\sum_{i=1}^k \sum_{x_j \in C_i} (x_j, c_i) \longrightarrow \max_{\mathbf{c}, \mathbf{r}} \|\mathbf{c}_i\| = 1$$

- iterative solution:

$$\mu_i = \frac{1}{|C_i|} \sum_{x_j \in C_i} x_j, \quad c_i = \frac{\mu_i}{\|\mu_i\|}, \quad r_j = \operatorname{argmax}_i (x_j, c_i)$$

# Text Clustering: Experimental Results

The quality is measured using  $F$ -measure.

Method	UPGMA		SL		DIANA		SKM	
	no	yes	no	yes	no	yes	no	yes
<b>M1</b>	1.00	<b>1.00</b>	1.00	<b>1.00</b>	1.00	<b>1.00</b>	1.00	<b>1.00</b>
<b>M2</b>	0.89	0.90	0.78	0.87	0.66	0.93	1.00	<b>1.00</b>
<b>M3</b>	0.61	0.75	0.35	0.53	0.48	0.56	0.79	<b>0.81</b>
<b>M4</b>	0.61	0.67	0.35	0.47	0.48	0.57	0.79	<b>0.80</b>

Semantic smoothing significantly enhances clustering performance

Spherical K-means shows the best results

In spherical K-means user statements can be easily formalized

## Questions of ФОМ 2010

[Create New Question](#)

Wording	Created on	Last Modified	Label	Additional Info	
Что из того, о чем говорил Д. Медведев на пресс-конференции, Вам больше всего запомнилось и понравилось?	24.09.2015 0:54:57	24.09.2015 0:55:19	Q1	Вопрос о Медведеве	<a href="#">Edit</a> <a href="#">Answers</a> <a href="#">Delete</a> <a href="#">Analyze</a>

[Return back to survey list](#)

# The Developed System

Fix cluster O молодёжи

**Apply and Recluster** [Save Analysis](#) [Return to Analyses list](#)

**Cluster Name**

Иновации

- иновации
- вводить иновации
- усовершенствование производства, иновации
- иновации на всех уровнях
- модернизируйтесь

**Cluster Name**

Техосмотр

- техосмотр
- про техосмотр
- об упрощении системы прохождения осмотров автомобилей
- он и сказал, что техосмотр теперь будут оформлять не в ГАИ, а при ОСАГО

**Cluster Name**

O молодёжи

- много молодёжи
- забота о детях, молодёжи
- уделяя внимание молодёжи
- обучение молодёжи рабочим специальностям
- хорошие перспективы для молодёжи
- наша молодёжь будет жить лучше
- Медведев болеет за молодёжь, даёт им работу.
- о школьниках, студентах
- молодёжные проблемы
- дорогу молодым, отставку пожилым

## Clustering Results

### Most Frequent Words:

МОЛОДЁЖЬ --- 7  
ИННОВАЦИЯ --- 4  
О --- 3  
ТЕХОСМОТР --- 3  
ЕСТЬ --- 2  
ОН --- 2  
НАШ --- 1  
ЖИТЬ --- 1  
ЛУЧШЕ --- 1  
ЗАБОТА --- 1

Export

### Select Action

Remove answers

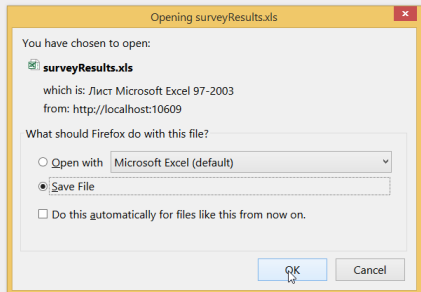
Apply and Recluster

[Save Analysis](#) [Return to Analyses list](#)

### Cluster Name

Иновации **FIXED**

- иновации  
 ВВОДИТЬ ИННОВАЦИИ



# Expert Coding: Experimental Results


Responses to three open-ended survey questions were coded using the implemented web service.


<b>Data Set</b>	<b>Responses</b>	<b>Clicks</b>	<b>Iterations</b>	<b>Clusters</b>
<b>Q1</b>	43	17	4	3
<b>Q2</b>	125	49	15	10
<b>Q3</b>	727	130	27	17


Number of Clicks < Number of coded responses

- The coding process with properties corresponding to domain requirements is proposed.
- Usage of machine learning and text mining techniques as an auxiliary instrument in coder's work allowed to achieve effort minimization.
- Implementation of web interface for open-ended coding allows to use cooperative methodology of coding, which enhances the quality of results.



 Loukashevich N.V.  
*Thesauri in problems of information retrieval.*  
Moscow University Printing House, 2011.

 Varlamov M. I., Korshunov A. V.  
Computing semantic similarity of concepts using shortest paths in  
Wikipedia link graph.  
*JMLDA*, 1107-1125, 2014.

 Boyarsky K.K., Kanevsky E.A., Saganenko G.I.  
On the issue of automatic text classification.  
*Economic-mathematical studies: mathematical models and  
information technology*, 253-273, 2009.