

# Методика нейросетевой кластеризации корпуса текстов

Стулов Виктор Викторович

Научный руководитель:  
Филиппович Андрей Юрьевич

МГТУ им. Баумана  
Кафедра ИУ-5  
НОК CLAIM

# Цель работы и решаемые задачи

Цель исследования: разработка методики автоматического выявления групп семантически похожих документов.

Назначение работы: методика предназначена для разработчиков систем информационного поиска.

Задачи исследования:

- Анализ существующих методов кластеризации корпуса текстов;
- Разработка методики нейросетевой кластеризации;
- Разработка архитектуры программного комплекса, реализующего отдельные этапы методики;
- Реализация и отладка программного комплекса.

# Классификация методов

## 1. По используемой модели текста


- a. Основанные на векторной модели текста; ←
- b. Основанные на модели суффиксного дерева;
- c. Основанные на графовой модели текста

## 2. По принципу функционирования

- a. Использующие формулы близости текстов; ←
- b. Генеративные алгоритмы;

## 3. По функциональности


- a. Иерархические (дивизимные и агломеративные); ←
- b. Плоские;



## 4. По характеру получаемых кластеров

- a. Мягкие; ←
- b. Жесткие;

# Нечеткая сеть Кохонена





1. Используется ориентированная на семантику векторная модель;
2. Для сокращения размерности пространства признаков - латентный семантический анализ;
3. Мера сходства текстов – скалярное произведение нормализованных векторов



# Нечеткая сеть Кохонена - результат

До обучения После обучения





$$\mu_{ij} = \begin{cases} \left( \frac{1}{\text{dist}(\mathbf{X}_j, \mathbf{W}_i) \sum_{p=1}^k \frac{1}{\text{dist}(\mathbf{X}_j, \mathbf{W}_p)}} \right)^{\frac{m}{(m-1)}} \\ 1, \text{ если } \text{dist}(\mathbf{X}_j, \mathbf{W}_i) = 0 \\ 0, \text{ если } \exists i: \text{dist}(\mathbf{X}_j, \mathbf{W}_i) = 0 \end{cases}$$

$$\mathbf{W}_i(t+1) = \mathbf{W}_i(t) + \frac{\sum_{j=1}^N \mu_{ij}(t)(\mathbf{X}_j - \mathbf{W}_i(t))}{\sum_{j=1}^N \mu_{ij}(t)}$$

$$m_t = m_0 - \frac{t(m_0 - 1)}{t_{max}}$$


# Определение количества кластеров




$$f(k) = \frac{\sum_{p=1}^k AVGu_j}{k} \rightarrow MAX$$

# Сокращение времени кластеризации


*Случай 1 - Укрупненный кластер не является плотным скоплением векторов*




*Случай 2 - Укрупненные кластеры разделяют между собой один или несколько кластеров*




*Случай 3 - укрупненные кластеры являются одним кластером*



*Случай 4 - укрупненный кластер содержит часть другого кластера*



# Алгоритм иерархической кластеризации - этап 1



# Этапы 2-9

**Расстояние между текстами:**


$$D(x_i, x_j) = \sqrt{\sum_k (x_{ik})^2} * \sqrt{\sum_k (x_{jk})^2} - \sum_k (x_{ik} * x_{jk})$$

**Сокращение размерности:**

{(car), (truck), (flower)} --> {(1.3452 \* car + 0.2828 \* truck), (flower)}

**Формула Эккарта — Янга:**

$$X_k = U_k D_k V_k^*$$




# Преимущества методики

- Использование модели текста, ориентированной на семантику;
- Вычислительная сложность на каждом уровне иерархии  $O(Nmt)$  в отличие от агломеративных методов;
- Автоматическое определение числа кластеров на каждом уровне иерархии;
- Кластеризация ограниченного количества текстов на каждом уровне иерархии;
- Устранение ошибок классификации с помощью процедуры слияния кластеров
- Построение таксономии, ориентированной априорные представления о ней пользователя:
- Гибкость построения систем поиска за счет использования нечеткой сети Кохонена.

# Эксперимент


- **Корпус текста: Reuters-21578**
- **Характеристики корпуса:** новости агентства Reuters за 1987 год, 9485 текста, количество кластеров – 57, количество слов от 6 до 1029
- **Опыт:** сравнение с алгоритмом k-means

## Схема обработки данных:




# Измеряемые параметры

## Время выполнения кластеризации



## Качество кластеризации



$$\text{Качество} = \frac{\text{число документов, кластеризованных верно}}{\text{общее число документов}}$$