



Московский государственный университет имени М.В. Ломоносова

Факультет вычислительной математики и кибернетики

Кафедра математических методов прогнозирования

Тематическое моделирование текстовых коллекций в диалоговых системах

Научный руководитель:

д.ф.-м.н., доцент, профессор РАН

К. В. Воронцов

Выполнил:

студент 417 группы

Н. Н. Кругликов

Москва, 2018

Содержание

1 Введение	3
2 Диалоговые системы	3
2.1 Целевые диалоговые системы	3
2.2 Нецелевые диалоговые системы	4
2.3 Оценка диалоговых систем	4
2.4 Практические аспекты реализации диалоговых систем	4
3 Вероятностное тематическое моделирование	6
3.1 PLSA	6
3.2 ARTM	6
3.3 Мультимодальные тематические модели	7
4 Методы суммаризации текстов	7
5 Тематическое моделирование в диалоговых системах	8
6 Тематическое моделирование в поисковых диалоговых системах	8
7 Эксперименты	10
7.1 Установка	10
7.2 Коллекция	10
7.3 Тематическая модель	11
7.4 Пользовательские оценки	12
8 Заключение	15
Список литературы	16

Аннотация

Задача построения виртуального собеседника является центральной в области обработки естественного языка. В последнее время диалоговые системы снова набирают популярность. Тематическое моделирование — способ извлечения скрытой структуры из коллекции текстовых документов. Несмотря на большой потенциал тематических моделей в информационном поиске, тематические модели до сих пор практически не применялись в системах диалогового поиска. В данной работе предложен способ применения полноценных тематических моделей в задаче построения нецелевой диалоговой системы; проведено сравнение метода с модификациями, использующими другие подходы — векторные представления и TF-IDF; разработана система для внедрения диалоговых систем и оценки пользователями разных методов выбора ответной реплики с помощью А/В тестирования.

1 Введение

Задача построения виртуального собеседника является центральной в области обработки естественного языка. В последнее время диалоговые системы снова набирают популярность. Многие крупные ИТ-системы создают диалоговые версии, такие как Siri (Apple), Cortana (Microsoft), Alexa (Amazon) и Алиса (Яндекс). [4]

Диалоговые системы бывают принято делить на (goal-oriented) и нецелевые (non-goal-oriented). Целевые диалоговые системы решают конкретную задачу пользователя и, как правило, взаимодействуют с внешним хранилищем данных. Нецелевые предназначены для развлечения пользователя с помощью имитации разговора с реальным собеседником. Нецелевые диалоговые системы могут быть порождающими (generative) и поисковыми (retrieval-based). Порождающие системы генерируют ответ с помощью некоторой порождающей модели текста, а поисковые выбирают ответ из набора готовых ответов.

Тематическое моделирование — способ извлечения скрытой структуры из коллекции текстовых документов. Тематическая структура помогает решать различные задачи из области обработки естественного языка, в том числе задачи информационного поиска. [15]

В настоящее время становится актуальной задача диалогового поиска [11], совмещающая подходы диалоговых систем и информационного поиска. Несмотря на большой потенциал тематических моделей в информационном поиске, тематические модели до сих пор практически не применялись в системах диалогового поиска. В данной работе исследуется возможность применения тематических моделей в этой области.

2 Диалоговые системы

2.1 Целевые диалоговые системы

Целевые диалоговые системы позволяют пользователю решить какую-нибудь конкретную задачу, например, заказать билет в кино. Целевые диалоговые системы, как правило, состоят из следующих компонент: [1]

- анализатор естественного языка (natural language understanding) преобразует высказывания пользователя в машинно-читаемую структуру данных;
- трекер состояния диалога (dialogue state tracker) определяет текущее состояние диалога, которое используется для выбора следующего действия;
- система определения действия (dialogue policy learning) выбирает следующее действие диалоговой системы в зависимости от текущего состояния;
- генератор естественного языка (natural language generator) преобразует результат действия из машинно-читаемой структуры в человеческий язык.

Каждая целевая диалоговая система создаётся и настраивается под конкретную задачу. При этом часто некоторые или все компоненты создаются инженерным методом, с большим числом вручную созданных правил. Такие системы невозможно перенастроить под другие задачи. В настоящие времена создание универсальной диалоговой системой является открытой проблемой.

2.2 Нецелевые диалоговые системы

Нецелевые диалоговые системы, также называемые чатботами, не пытаются решить конкретную задачу. Их цель в том, чтобы поддержать разговор с пользователем на произвольную тему.

Существует два основных подхода к построению нецелевых диалоговых систем — генеративный и поисковый.

В генеративном подходе ответ на сообщение пользователя порождается с помощью некоторой модели. В настоящее время наиболее популярный способ построения таких систем — seq2seq-модели.

В поисковом подходе ответ на сообщение пользователя выбирается из большого набора готовых ответов. Как правило, для сообщения и всех ответов строятся векторные представления одной размерности, после чего ответ выбирается в соответствии с некоторой метрикой.

2.3 Оценка диалоговых систем

Целевые диалоговые системы можно оценивать как по откликам пользователей, так и по критериями, соответствующим завершению цели — например, получилось ли у пользователя купить билет в кинотеатр, и сколько сообщений ему для этого потребовалось.

Нецелевые диалоговые системы можно оценивать по метрикам перекрытия, которые обычно используются для оценки автоматического перевода и суммаризации, таким как BLEU и ROUGE. Однако было показано [8], что эти метрики практически не коррелируют с пользовательскими откликами, которые, таким образом, остаются единственным разумным способом оценки таких систем.

2.4 Практические аспекты реализации диалоговых систем

Требования к диалоговым системам

Чтобы диалоговая система была готова к применению на практике, она должна удовлетворять следующих требований:

- Быстрое время ответа. Пользователь ожидает от диалоговой системы той же скорости реакции, что и от обычного человека, поэтому обрабатывать запрос в течение минуты недопустимо.

- Надёжность. Пользователь общается с диалоговой системой в удобное для него время. Если однажды диалоговая система не ответит из-за перегрузки или профилактических работ, пользователь может больше никогда к ней не обратиться.
- Лёгкость масштабирования. Диалоговая система за короткий промежуток времени может быстро стать популярной, при этом также возможны значительные снижения нагрузки, например, в ночное время. Необходимо эффективно использовать вычислительные ресурсы, чтобы не допускать ни замедления работы под нагрузкой, ни простоя большого количества мощностей.

Диалоговые программные интерфейсы

В последнее время многие популярные веб-сервисы предоставляют сторонним разработчикам программные интерфейсы (API) для разработки диалоговых систем, интегрированных в этот сервис. В частности, такие интерфейсы предоставляют социальные сети ВКонтакте и Facebook, а также мессенджеры WhatsApp, Telegram и Viber.

Как правило, программные интерфейсы для диалоговых систем поддерживают два режима работы. В одном режиме работы, называемом long polling, стороннее приложение периодически запрашивает у сервиса новые события, такие, как сообщения от пользователей. В другом режиме, называемом callback или webhook, сервис самостоятельно оповещает стороннее приложение о новых событиях по заранее определённому URL-адресу.

Первый режим проще в использовании, но у него есть ряд недостатков. Во-первых, он нерационально расходует ресурсы процессора, поддерживая сетевое соединение, по которому сравнительно редко передаются данные. Во-вторых, в таком режиме заметно ограничена скорость реагирования диалоговой системы на сообщения пользователей.

Бессерверная архитектура

Облачные платформы, такие как Amazon Web Services [2] или Google Cloud Platform, позволили разработчикам веб-приложений гибко управлять вычислительными ресурсами. Программные интерфейсы облачных платформ дают возможность определять серверы, базы данных и сетевые соединения в терминах кода (*Infrastructure as Code*).

Новая парадигма в облачных вычислениях — бессерверная архитектура (*serverless*) — является логичным продолжением *Infrastructure as Code*. В этой парадигме понятие сервера полностью абстрагируется от разработчика, которому теперь достаточно реализовать функцию без побочных эффектов. Загруженная в облако функция вызывается в ответ на определённые события, а стоимость вычислительных ресурсов вычисляется на миллисекундной основе. При этом горизонтальное масштабирование полностью реализуется облачной платформой, прозрачно для разработчика.

Бессерверная архитектура позволяет разрабатывать быстрые, надёжные и легко масштабируемые диалоговые системы [3]. Время ответа такой диалоговой системы практически не

зависит от количества пользователей.

3 Вероятностное тематическое моделирование

Тематическое моделирование — метод выявления скрытой семантической структуры в корпусе текстов.

Формально, пусть D — множество документов в корпусе, W — множество слов. Предположим, что существует множество тем T и автор текста, пишя слово w в документе d , задумывал некую тему t . Тогда можно считать, что коллекция текстов представляет собой набор троек (d, w, t) , взятых из дискретного распределения $p(d, w, t)$ на множестве $D \times W \times T$.

Добавим ещё одно условие — гипотезу условной независимости. Будем считать, что появление слова с темой t не зависит от документа, в котором появилось это слово:

$$p(w|t, d) = p(w|t)$$

Обозначим $p(w|t) = \phi_{wt}$ и $p(t|d) = \theta_{td}$. Тогда тематическую модель можно записать в виде

$$p(w|d) = \sum_{t \in T} p(w|t)p(t | d) = \sum_{t \in T} \phi_{wt}\theta_{td}$$

Построение тематической модели — задача восстановления распределений $p(w|t)$ и $p(t|d)$.

3.1 PLSA

PLSA [7] — простейшая вероятностная тематическая модель.

Для восстановления распределений максимизируется логарифм правдоподобия

$$L(\Phi, \Theta) = \sum_{d \in D} \sum_{w \in W} n_{dw} \ln \sum_{t \in T} \phi_{wt}\theta_{td} \rightarrow \max_{\Phi, \Theta}$$

при ограничениях

$$\sum_{w \in W} \phi_{wt} = 1, \phi_{wt} \geq 0; \quad \sum_{t \in T} \theta_{td} = 1, \theta_{td} \geq 0$$

Эта задача решается с помощью EM-алгоритма. На E-шаге по ϕ_{wt} и θ_{td} вычисляются вероятности $p(t|d, w)$ для всех $t \in T$, $d \in D$, $w \in W$. На M-шаге по вероятностям $p(t|d, w)$ вычисляются параметры ϕ_{wt} и θ_{td} . Изначальное приближение параметров ϕ_{wt} и θ_{td} генерируется случайно.

3.2 ARTM

Модель ARTM [15] является обобщением модели PLSA. К логарифму правдоподобия прибавляются регуляризаторы $R_i(\Phi, \Theta)$ с коэффициентами регуляризации τ_i .

Эта задача также решается с помощью EM-алгоритма, с небольшими модификациями M-шага.

Модель ARTM предоставляет широкие возможности по описанию требований к тематической модели с помощью регуляризаторов. Большинство тематических моделей, основанных на байесовском подходе, можно выразить с помощью ARTM, в том числе наиболее часто использующуюся на практике модель LDA.

3.3 Мультимодальные тематические модели

Более обобщённым подходом к вероятностному тематическому моделированию являются мультимодальные тематические модели. В мультимодальных моделях предполагается, что каждому документу документ описывается не только своим мешком слов, но и набором дополнительной информации, в качестве которой могут выступать автор текста или набор вручную проставленных тэгов.

При построении мультимодальной тематической модели оптимизируемый функционал представляет собой сумму логарифмов правдоподобия (с регуляризаторами, в случае ARTM) для каждой модальности.

4 Методы суммаризации текстов

Задача суммаризации заключается в уменьшении объёма текста без потери смысла. Методы суммаризации делятся на извлекающие (extractive) и порождающие (abstractive) [6]. Извлекающие методы строят суммаризации из фрагментов изначального текста, а порождающие используют модели порождения текста.

Как правило, извлекающие методы делят текст на фрагменты, ранжируют их согласно некоторому критерию и строят суммаризацию из N лучших предложений, где N — параметр алгоритма. Графовые методы суммаризации используют идеи, вдохновлённые алгоритмом PageRank, придуманным основателями Google для ранжирования веб-страниц. В качестве вершин графа вместо страниц используются фрагменты текста (например, LexRank использует слова, а TextRank — предложения), а в качестве рёбер — определённые каким-либо образом связи между предложениями.

Алгоритм TextRank [10] строит на предложениях текста взвешенный граф, где вес ребра определяется количеством общих слов в предложении, нормированных на их длину:

$$\text{Similarity}(S_i, S_j) = \frac{|\{w_k \mid w_k \in S_i, w_k \in S_j\}|}{\log |S_i| + \log |S_j|}$$

Затем вершинам присваиваются случайные веса, которые пересчитываются до сходимости по формуле:

$$WS(V_i) = (1 - d) + d \star \sum_{V_j \in In(V_i)} \frac{w_{ji}}{\sum_{V_k \in Out(V_j)} w_{jk}} WS(V_j)$$

Здесь через V_i , V_j обозначены вершины графа, через w_{ij} — веса рёбер, а d — параметр, лежащий между 0 и 1 и устанавливаемый авторами на 0.85. Это формула является адаптацией формулы, предложенной в методе PageRank для ориентированных невзвешенных графов.

5 Тематическое моделирование в диалоговых системах

Практика применения тематического моделирования в диалоговых системах достаточно невелика. Одной из преград к применению тематических моделей является так называемая проблема коротких текстов. Проблема заключается в том, что задача тематического моделирования достаточно устойчиво решается на коллекциях, состоящих из достаточно длинных документов. Если документы сопоставимы по размеру с типичным сообщением в мессенджере, строить тематические модели традиционными способами не получается. Для этих случаев разработаны тематические модели с дополнительными ограничениями, например, модель TwitterLDA добавляет предположение, что каждый документ содержит только одну тему.

В существующей литературе по нецелевым диалоговым системам тематическое моделирование используется только в качестве вспомогательной информации для порождающих seq2seq сетей [12, 13]. Как правило, авторы используют TwitterLDA для моделирования большой коллекции коротких сообщений.

В данной работе выбран иной подход. В качестве источника ответов на реплики пользователя рассматривается коллекция текстовых документов, длина которых позволяет построить полноценную тематическую модель. Для того, чтобы извлечь из длинного документа ответ подходящей длины, используются методы суммаризации.

6 Тематическое моделирование в поисковых диалоговых системах

В поисковых диалоговых системах ответ на реплику пользователя r выбирается из массива готовых ответов a . Для этого реплика пользователя и все ответы из массива переводятся в векторное пространство одной размерности, а затем выбирается наиболее близкий по некоторой метрике ответ:

$$a^* = \underset{a}{\operatorname{argmin}} d(q(r), b(a)),$$

где q , b — функции отображения текста в векторное пространство.

Пусть имеется коллекция текстов x . Получим из неё набор ответов с помощью алгоритма суммаризации σ :

$$a = \sigma(x).$$

У нас есть два способа получить вектор, соответствующий ответу: перевести в векторное

пространство исходный документ x или его суммариацию $\sigma(x)$. Мы будем рассматривать оба варианта.

Сравним три способа отображения текстов в векторное пространство: основанный на тематических моделях, основанный на векторных представлениях слов и основанный на TF-IDF. Во всех случаях в качестве метрики $d(\cdot, \cdot)$ будем использовать косинусное расстояние.

Тематические модели

Пусть по коллекции текстов x построена тематическая модель (Φ, Θ) .

Определим для реплики пользователя r тематический вектор $q(r)$ как среднее тематических векторов по словам реплики:

$$q(r) = \frac{\sum_w p(t|w)}{|r|}$$

Оценим тематический вектор $b_\sigma(\sigma(x))$ каждой суммаризации как среднее векторов $p(t|x, w)$ по словам суммаризации:

$$b_\sigma(\sigma(x)) = \frac{\sum_w p(t|x, w)}{|\sigma_x|}$$

В качестве тематического вектора исходного документа $b_x(x)$ достаточно взять соответствующий столбец матрицы Θ :

$$b_x(x) = p(t|x) = \theta_x$$

Векторные представления

Одним из популярных способов переводить текст в векторное пространство являются векторные представления дистрибутивной семантики. Мы воспользуемся моделью Continous SkipGram [5], обученной на Национальном Корпусе Русского Языка и русской Википедии [9]. Как реплику пользователя, так и ответы будем переводить в векторное пространство через усреднение векторных представлений.

TF-IDF

Мера TF-IDF часто используется в задачах информационного поиска. Для каждого слова в каждом документе вычисляется его частота в рамках этого документа, которая затем умножается на обратную документную частоту этого слова. Таким образом, каждый документ можно отобразить в векторное пространство размерности, совпадающей с размером словаря.

Мы будем считать документами как реплики пользователя, так и возможные ответы.

7 Эксперименты

7.1 Установка



Рис. 1: Пример работы системы

Названная диспетчером, отвечает за взаимодействие с программным интерфейсом Telegram, а также хранение сообщений и оценок пользователей. Каждое сообщение, полученное от пользователя, отправляется во вторую часть, названную экспериментом. Каждый эксперимент — это метод, принимающий на вход идентификатор пользователя и сообщение, и возвращающий ответ. Экспериментов несколько, что позволяет проводить сравнение с помощью А/В тестирования разных методов построения нецелевых диалоговых систем.

Разработанная архитектура обеспечивает медианное время ответа меньше одной секунды вне зависимости от количества пользователей.

7.2 Коллекция

В качестве коллекции текстов был взят набор научно-популярных статей с сайта «Постнаука». Собранный датасет содержит 2976 документов. Одна из особенностей портала — богатая коллекция тэгов, вручную приставленная редакторами под каждой статьёй. Всего, за исключением стопслов, в коллекции 43196 уникальных леммы, а также 1799 тэгов.

Для проведения экспериментов необходимо тестиировать диалоговую систему на реальных пользователях. Была разработана приложение для тестирования разных диалоговых систем, позволяющее собирать оценки пользователей.

В качестве платформы для реализации диалоговой системы был выбран мессенджер Telegram. Преимущество этой платформы состоит, во-первых, в большом количестве активных русскоязычных пользователей, а во-вторых, в богатых возможностях программного интерфейса для диалоговых систем, позволяющего, в частности, легко добавить функциональность оценки сообщений системой пользователями.

В качестве облачного провайдера был выбран Amazon Web Services [2]. Этот провайдер одним из первых запустил поддержку бессерверных приложений и предоставляет богатый набор инструментов, помогающих интегрировать бессерверные приложения с базами данных и другими ресурсами.

Архитектура разработанной системы состоит из двух основных независимых частей. Первая часть,

названная экспериментом, отвечает за взаимодействие с программным интерфейсом Telegram, а также хранение сообщений и оценок пользователей. Каждое сообщение, полученное от пользователя, отправляется во вторую часть, названную экспериментом. Каждый эксперимент — это метод, принимающий на вход идентификатор пользователя и сообщение, и возвращающий ответ. Экспериментов несколько, что позволяет проводить сравнение с помощью А/В тестирования разных методов построения нецелевых диалоговых систем.

7.3 Тематическая модель

По коллекции статей с «Постнауки» была построена тематическая модель с 20 темами (одна из них — фоновая). Для улучшения качества модели была использована модальность тэгов.

топ-токены	топ-тэги
вид	эволюция
эволюция	биология
группа	антропология
организм	человек
ген	палеонтология
эволюционный	антропогенез
раса	физиология
возникать	происхождение_человека
отбор	эволюционная_биология
часть	иммунитет

Таблица 1: Топ-токены и топ-тэги первой темы модели

В качестве метода суммаризации была выбрана открытая реализация метода TextRank с небольшими модификациями [14]. Количество слов в суммаризации N_{sum} является гиперпа-

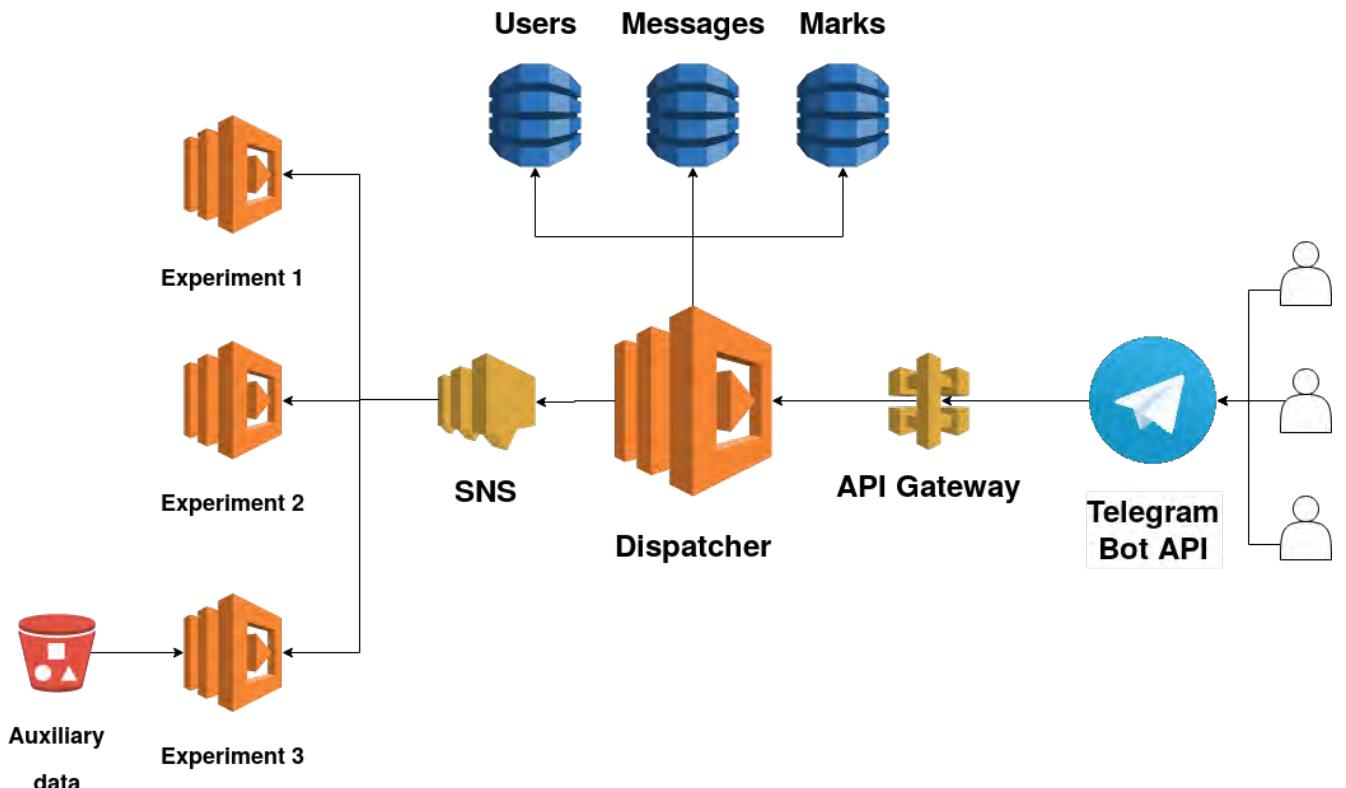


Рис. 2: Архитектура системы

раметром. Было проведено три варианта экспериментов с $N_{sum} = 50, 100$ и 150 .

7.4 Пользовательские оценки

Пользователь: Можно ли вылечить рак содой

Система: Существует взаимосвязь между увеличением употребления в пищу жиров и повышением уровня холестерина в крови, и оба эти фактора наряду с ростом уровня женских гормонов, в свою очередь, положительно коррелируют с увеличением частоты возникновения рака молочной железы и наступлением менархе в более раннем возрасте.

Таблица 2: Пример ответа, оценённого на 5

Пользователь: Когда я зеваю, у меня открывается рот. Многие говорят, что это потому, что я хочу спать, но на самом деле потому что я хочу проснуться. Почему человек зевает?

Система: Пытаться продолжить все виды деятельности, которые прямо не связаны с приобретением и собственностью, а это очень сложный вопрос, потому что в основном мы сейчас переживаем в развитых странах эпоху глобального капитализма, которая означает, что каждый человек вовлечен в некоторый процесс конкуренции, касающейся личной собственности и личного заработка.

Таблица 3: Пример ответа, оценённого на 1

В ходе эксперимента было собрано около 500 оценок от 90 пользователей.

Пользователи оценивали ответы по пятибалльной шкале в соответствие со следующими критериями:

1. ответ совершенно не соответствует теме запроса
2. ответ практически не соответствует теме запроса
3. ответ отчасти соответствует теме запроса
4. ответ практически соответствует теме запроса
5. ответ полностью соответствует теме запроса.

Было проведено сравнение трёх методов векторизации текстов — тематических моделей, векторных представлений и TF-IDF. Каждый метод был представлен в двух вариантах — с векторизацией суммаризации и с векторизацией исходного документа. Учитывая, что сравнивалось также три разных длины суммаризации, всего было 18 вариантов эксперимента.

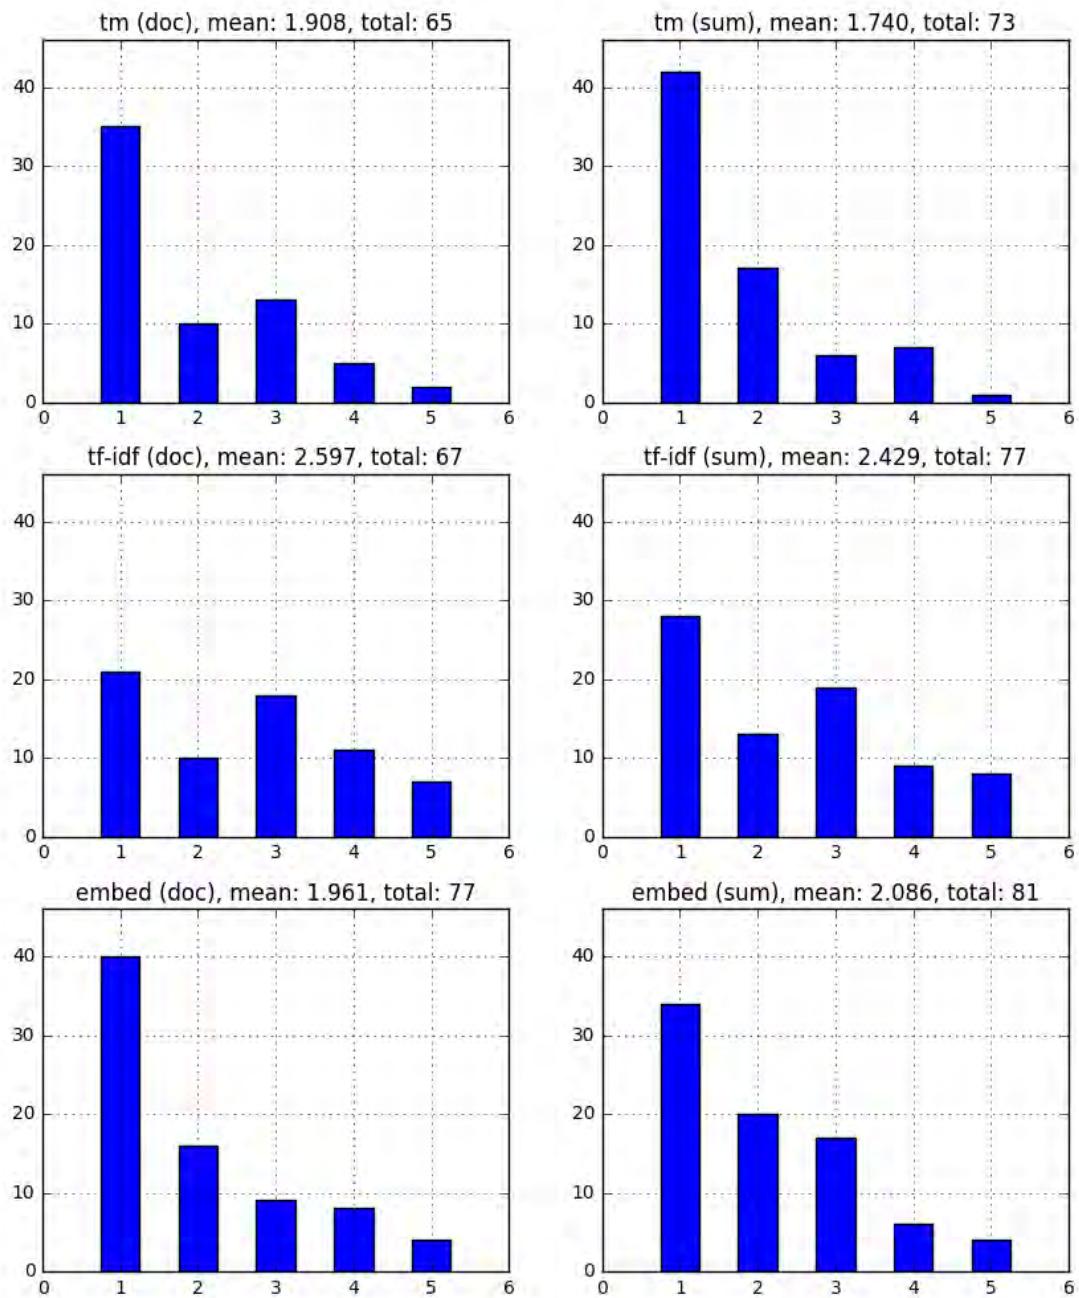


Рис. 3: Распределение оценок пользователей в разных методах

Тематические модели	doc	50	2.07
		100	2.26
		150	1.43
	sum	50	1.58
		100	1.75
		150	1.81
	doc	50	2.54
		100	1.75
		150	1.80
Векторные представления	sum	50	2.33
		100	2.34
		150	1.52
	doc	50	2.42
		100	3.00
		150	2.53
TF-IDF	sum	50	2.44
		100	2.33
		150	2.48

Таблица 4: Пользовательские оценки методов выбора ответа

Каждый вариант метода выбора ответа выбирался случайным образом для каждой реплики пользователя.

Разные методы хорошо себя показывают в разных ситуациях. TF-IDF хорошо работает на коротких запросах. Поскольку пользователи часто пишут короткие реплики, похожие на запросы в поисковую систему, методы, основанные на TF-IDF, получили самые высокие пользовательские оценки.

Тематические модели и векторные представления хорошо работают в случаях, когда нужно найти ответ не по точному совпадению слов в запросе, а по смыслу.

Усреднённые пользовательские оценки различных методов приведены в таблице 7.4. На рисунке 3 изображены распределения пользовательских оценок в целом по всем длинам суммаризаций.

К сожалению, коллекция, использованная для тестирования методов, достаточно мала. Плохие оценки пользователей часто были связаны с тем, что в среди имеющихся вариантов нет достаточно подходящего по теме ответа.

Кроме того, часто пользователи формулировали вопросы точного, фактического характера: «Сколько спутников у Юпитера», «Когда родился Наполеон» и подобное. Поисковые диалоговые системы не предназначены для генерации хороших ответов на такие вопросы, для этого лучше подходят вопросно-ответные системы.

8 Заключение

В работе достигнуты следующие результаты:

- предложен способ применения полноценных тематических моделей в задаче построения нецелевой диалоговой системе;
- проведено сравнение метода, основанного на тематических моделях, с модификациями, использующими другие подходы — векторные представления и TF-IDF;
- разработана готовая к применению в реальных приложениях система для внедрения диалоговых систем и оценки пользователями разных методов выбора ответной реплики с помощью А/В тестирования.

Дальнейшее улучшение возможно за счёт увеличения текстовой коллекции и комбинирования различных методов векторизации текста.

Список литературы

- [1] A Survey on Dialogue Systems: Recent Advances and New Frontiers / H. Chen, X. Liu, D. Yin, J. Tang. — 2017. — no. 1.
<http://arxiv.org/abs/1711.01731>.
- [2] Amazon Web Services Inc. Overview of Amazon Web Services // White Paper. — 2015. — no. December.
<https://docs.aws.amazon.com/aws-technical-content/latest/aws-overview/aws-overview.pdf?ic>
- [3] Building a Chatbot with Serverless Computing / M. Yan, P. Castro, P. Cheng, V. Ishakian // Proceedings of the 1st International Workshop on Mashups of Things and APIs - MOTA '16. — 2016. — Pp. 1–4.
<http://dl.acm.org/citation.cfm?doid=3007203.3007217>.
- [4] DALE R. The return of the chatbots // Natural Language Engineering. — 2016. — Vol. 22, no. 5. — P. 811–817.
- [5] Distributed representations of words and phrases and their compositionality / T. Mikolov, I. Sutskever, K. Chen et al. // CoRR. — 2013. — Vol. abs/1310.4546.
<http://arxiv.org/abs/1310.4546>.
- [6] Gambhir M., Gupta V. Recent automatic text summarization techniques: a survey // Artificial Intelligence Review. — 2017. — jan. — Vol. 47, no. 1. — Pp. 1–66.
<http://link.springer.com/10.1007/s10462-016-9475-9>.
- [7] Hofmann T. Probabilistic latent semantic analysis // Proc. of Uncertainty in Artificial Intelligence, UAI'99. — 1999. — P. 21.
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.84.1137&rep=rep1&type=pdf>.
- [8] How NOT to evaluate your dialogue system: An empirical study of unsupervised evaluation metrics for dialogue response generation / C. Liu, R. Lowe, I. V. Serban et al. // CoRR. — 2016. — Vol. abs/1603.08023.
<http://arxiv.org/abs/1603.08023>.
- [9] Kutuzov A., Kuzmenko E. Webvectors: A toolkit for building web interfaces for vector semantic models // Communications in Computer and Information Science / Ed. by D. I. Ignatov, M. Y. Khachay, V. G. Labunets et al. — Cham: Springer International Publishing, 2017. — Vol. 661. — Pp. 155–161.
http://dx.doi.org/10.1007/978-3-319-52920-2_15.
- [10] Mihalcea R., Tarau P. TextRank: Bringing order into texts // Proceedings of EMNLP. — 2004. — Vol. 85. — Pp. 404–411.
<http://acl.ldc.upenn.edu/acl2004/emnlp/pdf/Mihalcea.pdf>.

- [11] Radlinski F., Craswell N. A Theoretical Framework for Conversational Search // *Proceedings of the 2017 Conference on Conference Human Information Interaction and Retrieval - CHIIR '17*. — 2017. — Pp. 117–126.
<http://dl.acm.org/citation.cfm?doid=3020165.3020183>.
- [12] Response Selection with Topic Clues for Retrieval-based Chatbots / Y. Wu, W. Wu, Z. Li, M. Zhou. — 2016.
<http://arxiv.org/abs/1605.00090>.
- [13] Topic Aware Neural Response Generation / C. Xing, W. Wu, Y. Wu et al. — 2016. — Pp. 3351–3357.
<http://arxiv.org/abs/1606.08340>.
- [14] Variations of the Similarity Function of TextRank for Automated Summarization / F. Barrios, F. López, L. Argerich, R. Wachenchauzer. — 2016.
<http://arxiv.org/abs/1602.03606>.
- [15] Vorontsov K., Potapenko A. Additive regularization of topic models // *Machine Learning*. — 2015. — Vol. 101, no. 1-3. — Pp. 303–323.
<http://machinelearning.ru/wiki/images/4/47/Voron14mlj.pdf>.