

Impact Factor:

ISRA (India) = 4.971
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
PIHII (Russia) = 0.126
ESJI (KZ) = 8.716
SJIF (Morocco) = 5.667

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

SOI: [1.1/TAS](#) DOI: [10.15863/TAS](#)

International Scientific Journal Theoretical & Applied Science

p-ISSN: 2308-4944 (print) e-ISSN: 2409-0085 (online)

Year: 2019 Issue: 12 Volume: 80

Published: 30.12.2019 <http://T-Science.org>

QR – Issue



QR – Article



Marina Vladimirovna Shkurina

Peter the Great St. Petersburg Polytechnic University
Master's Student
Institute of Computer Science and Technology

Oleg Yurievich Sabinin

Peter the Great St. Petersburg Polytechnic University
Candidate of Engineering Sciences, Docent
Institute of Computer Science and Technology

RHETORICAL STRUCTURE THEORY AND ITS APPLICATION TO AUTOMATIC TEXT SUMMARIZATION

Abstract: Due to the growth of text data online the task of automatic text summarization attracts more and more interest. Despite recent success in this field, modern summarization methods still have their drawbacks, and one of them is how the resulting summaries aren't always the most coherent. In this article the Rhetorical Structure Theory and the possibility of using it to overcome this problem are explored.

Key words: Automatic Text Summarization, Rhetorical Structure Theory, Discourse Structure, Natural Language Processing, Text Analysis, Data Mining.

Language: Russian

Citation: Shkurina, M. V., & Sabinin, O. Y. (2019). Rhetorical structure theory and its application to automatic text summarization. *ISJ Theoretical & Applied Science*, 12 (80), 521-528.

Soi: <http://s-o-i.org/1.1/TAS-12-80-99> **Doi:**  <https://dx.doi.org/10.15863/TAS.2019.12.80.99>

Scopus ASCC: 1700.

ТЕОРИЯ РИТОРИЧЕСКОЙ СТРУКТУРЫ И ЕЕ ПРИМЕНЕНИЕ В ОБЛАСТИ АВТОМАТИЧЕСКОГО АННОТИРОВАНИЯ ТЕКСТА

Аннотация: В связи с ростом объема текстовой информации в Интернете все более актуальной становится задача автоматического аннотирования текста. Несмотря на успехи в этой области, современные методы имеют свои недостатки, и одним из них является возможность получения несвязного текста. В данной статье рассматривается теория риторической структуры и возможность ее применения для преодоления этой проблемы.

Ключевые слова: Автоматическое аннотирование текста, теория риторической структуры, структура дискурса, обработка естественного языка, анализ текста, анализ данных.

Введение

Уже сегодня людям доступны огромные объемы информации в Интернете, и эти объемы растут с каждым днем. Это делает задачу поиска нужной и важной информации в сжатые сроки невероятно сложной.

В связи с этим представляет интерес задача автоматического аннотирования текста, решение которой позволит генерировать небольшие, но

содержательные тексты, излагающие ключевые идеи исходного документа.

Исследования в этой области начались еще в 1950-е годы и продолжают по сей день. Развитие методов машинного и глубокого обучения дало значительные толчки для появления новых методов, но всё ещё остается большое количество проблем, которые требуют решения. В частности, одной из проблем является улучшение связности и логичности генерируемой аннотации.

Impact Factor:

ISRA (India) = 4.971
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 0.126
ESJI (KZ) = 8.716
SJIF (Morocco) = 5.667

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

Теория риторической структуры, предложенная для описания дискурса, как раз позволяет описать и оценить связность текста, и это позволяет предположить, что ее использование в задаче автоматического аннотирования текста может помочь с решением указанной проблемы.

В данной статье будут рассмотрены основные положения теории риторической структуры и методы построения дерева дискурса. Также будут рассмотрены подходы к автоматическому аннотированию текста, будут выявлены их основные проблемы и будет рассмотрена возможность применения теории риторической структуры для их решения.

Теория риторической структуры

Хорошо написанный текст – это не просто набор независимых предложений, это последовательность предложений, где смысл каждого предложения связан с предыдущими и последующими. Структурированные и связанные группы предложений называются дискурсом, а под дискурсивным анализом понимается уровневый раздел лингвистики, изучающий языковые единицы максимального и, в принципе, неограниченного объема [1].

Было показано, что анализ дискурсивной структуры текста может помочь при решении большого спектра задач обработки естественного языка: аннотирование текста и сжатие, генерация текста, оценка машинного перевода, анализ тональности текста, создание вопросно-ответных систем, разрешение кореферентности.

Существуют различные подходы к описанию теории дискурса, но наибольшую популярность получила теория риторической структуры У. Манна и С. Томпсон, описанная в работе [2].

Авторы выделяют три уровня структуры [3]:

- суперструктура – структура, зависящая от жанровой принадлежности текста и его разновидности;

- структура связей – структура, обеспечивающая связность и единство текста;

- синтаксическая структура – в традиционном понимании.

ТРС относится ко второму типу, то есть является теорией структуры связей.

Ключевыми понятиями ТРС являются отношения и дискурсивные единицы. Дискурсивная единица – это любой отрывок текста, обладающий ТРС-структурой (то есть обладающий функциональной независимостью, с точки зрения организации текста) или элементарная дискурсивная единица (ЭДЕ), которая обычно представляет из себя клаузу.

Таким образом, текст описывается как древовидная иерархическая структура, в которой дискурсивные единицы связаны отношениями, а листьями являются ЭДЕ.

Авторы вводят 23 отношения, которые делятся на два вида: одноядерные отношения соединяют ядро (основную смысловую сегмент) и сателлит (дополнительную информацию), а мультиядерные отношения – это отношения между двумя и более равнозначными дискурсивными единицами.

Методы автоматического определения структуры дискурса

Построение ТРС для текста обычно делится на два этапа: *выделение ЭДЕ* и *определение отношений между дискурсивными единицами*. Неправильная сегментация текста на первом этапе ведет к распространению ошибки на последующие шаги и невозможности получения достоверных результатов, поэтому этот этап является ключевым для корректного построения риторической структуры текста.

Первые методы, предложенные для анализа структуры дискурса, были основаны на правилах. Довольно часто союзы (*хотя, но, потому что* и другие) могут указывать на тип отношения, связывающего два фрагмента текста. В работе [4] автор использует набор правил, основанных на использовании маркеров и составленных вручную после обширного изучения корпуса данных, чтобы сегментировать текст и определять отношения сначала внутри предложений, затем внутри параграфов и так далее. У такого подхода есть свои недостатки:

- определение маркеров дискурса сама по себе сложная задача, так как в зависимости от употребления одна и та же фраза может указывать, а может и не указывать на дискурсивное отношение;

- сегментация на основе только маркеров не достигает высокой точности;

- маркеры дискурса не всегда однозначны – некоторые из них могут указывать на несколько различных отношений;

- риторические отношения не всегда связаны с наличием маркеров.

В России исследователи тоже разрабатывали свои методы. В частности, в работах [5–7] предлагается использование маркеров, а также расширяется формализация основных понятий теории риторической структуры, чтобы ее можно было применять в вычислительных моделях. Вводится критерий корректности структуры текста, который используется для генерации альтернативных корректных структур исходного текста, и на основе введенной метрики выбирается оптимальный вариант. Этот алгоритм они предложили в рамках разработки системы автоматического реферирования научно-технических текстов на русском языке, и разработанный словарь ключевых фраз является узкоспециализированным, то есть не применим для текстов другого стиля.

Impact Factor:

ISRA (India) = 4.971
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 0.126
ESJI (KZ) = 8.716
SJIF (Morocco) = 5.667

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

Как можно заметить, использование правил для анализа риторических отношений сопряжено с большим количеством ограничений, и намного более точные результаты можно получить при использовании техник машинного обучения с учителем на основе размеченного корпуса текстов. Именно на таких методах и сосредоточилось внимание исследователей. Для работы этих методов важен выбор признаков для обучения, и в работе [8] было эмпирически показано, что наблюдается связь между синтаксической и риторической структурой на уровне предложения. Это значит, что в качестве признаков для обучения можно в том числе использовать результаты синтаксического анализа.

1.1.1. Сегментация текста на ЭДЕ

Сегментацию текста можно рассматривать как задачу бинарной классификации или как задачу разметки последовательностей, где для токенов текста необходимо предсказать последовательность меток 'да/нет', то есть является ли токен границей ЭДЕ или нет. Для решения этой задачи традиционные подходы используют условные случайные поля (CRF), где в качестве признаков, помимо прочего, могут использоваться морфологические и синтаксические признаки. Однако, в связи с тем, что метки 'да' встречаются значительно реже, зависимости между метками сложнее определить и использование CRF может не давать выигрыша по сравнению с бинарными классификаторами [9].

Но сегодня наблюдается смещение в сторону использования рекуррентных нейронных сетей (РНС), которые могут использовать CRF-слой на выходе [10]. Достоинство таких методов заключается в том, что для них не нужно вручную выбирать признаки для обучения [11].

Наилучшие результаты сегментации для корпуса английских текстов RST-DT сегодня показывают именно модели, использующие РНС. В частности, в работе [12] предлагается использовать архитектуру biLSTM-CRF, предложенную в [13] для задачи распознавания именованных сущностей. Авторы адаптируют ее для сегментации текста на ЭДЕ в двух аспектах: во-первых, так как исходный корпус текстов достаточно мал для глубокого обучения, используются предобученные векторные представления слов. Во-вторых, используется механизм ограниченного внимания, который позволяет захватывать полезную информацию в окрестности фиксированного размера, но при этом игнорировать ненужный шум. Это мотивируется тем фактом, что границы определяются на основе информации из соседних ЭДЕ.

Помимо того, что эта модель показывает отличные результаты, авторы также заявляют о высокой скорости работы по сравнению с другими

открытыми системами. Это связано с тем, что предыдущие методы извлекали большое количество признаков для предсказаний.

Примерно в это же время появляется работа [14], в которой предлагается рассматривать задачу сегментации как задачу предсказания последовательности и использовать модель seq2seq, которая успешно применяется в области машинного перевода. Модель seq2seq состоит из двух РНС: кодера, обрабатывающего входную последовательность, и декодера, генерирующего выходную последовательность. Ограничение такой модели заключается в том, что словарь выходных данных (т.е. словарь, из которого выбираются элементы для выходной последовательности) фиксирован и не зависит от входных данных. Для преодоления этого ограничения авторы предлагают использовать механизм, описанный в работе [15], позволяющий создавать словарь непосредственно в процессе обработки, используя входную последовательность в качестве словаря для выбора элементов выходной последовательности.

В [11] авторы используют аналогичную архитектуру, но вносят несколько ключевых изменений: так, вместо предобученных векторных представлений слов используются контекстуализированные модели ELMo, декодер принимает на вход не векторные представления слов, а состояние кодера, и предлагается использовать другой механизм внимания.

1.1.2. Построение дерева риторической структуры

Методы для построения дерева можно разделить на *жадные алгоритмы на основе переходов* (transition-based) и *анализ с помощью схем* (chart parsing) [11]. В первом случае дерево строится пошагово на основе последовательного принятия решений о переносе-свертке. Создается стек, содержащий поддеревья риторической структуры, и перенос создает новое поддерево для следующей рассматриваемой ЭДЕ, а свертка создает новые поддеревья из поддеревьев с вершины стека.

Достоинство такого подхода заключается в линейной зависимости времени парсинга от количества ЭДЕ. Однако его ограничивает то, что решение на каждом шаге зависит только от локальной информации.

Методы анализа с помощью схем обучают функцию стоимости для поддеревьев дискурса и с помощью динамического программирования осуществляют поиск по всем возможным деревьям, чтобы найти наиболее вероятное. Такие методы более точны, чем методы на основе переходов, но работают намного медленнее.

Исследователи также заметили, что распределение частот встречаемости отношений отличается, если рассматривать связи внутри

Impact Factor:

ISRA (India) = 4.971
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 0.126
ESJI (KZ) = 8.716
SJIF (Morocco) = 5.667

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

одного предложения или между разными предложениями. Так, в [9] было замечено, что в обучающей выборке корпуса RST-DT отношение Same-Unit (Одна единица), например, чаще связывает дискурсивные единицы одного предложения, а отношение Contrast (Контраст) – дискурсивные единицы разных предложений.

В связи с этим предлагаются методы, которые используют разные модели для определения отношений внутри предложений и между предложениями. В работе [9] система парсинга состоит из двух модулей: первый модуль строит одно или несколько поддеревьев дискурса для каждого предложения, а второй модуль генерирует полное дерево на основе этих поддеревьев. Оба модуля используют один и тот же алгоритм для парсинга, но работают с разными моделями.

В работе [16] авторы предлагают двухшаговый метод – на первом шаге строится структура дерева, а на втором уже расставляются метки отношений. Они считают, что наличие структуры позволяет улучшить процесс классификации отношений. Например, некоторые отношения чаще находятся ближе к корню дерева, в то время как другие оказываются дальше. К тому же, это позволяет более явно выделить отношения на разных уровнях, и авторы для второго шага выделяют три классификатора: помимо отношений внутри предложений и между разными предложениями в этой работе выделяют также и третий уровень – отношения между параграфами.

1.1.3. Оценка результата

Отдельным вопросом стоит оценка результата. Для оценки сегментации применяются стандартные метрики оценки бинарных классификаторов: точность (precision), полнота (recall) и F-мера. Точность оценивает, какая доля токенов, распознанных как границы ЭДЕ, была предсказана верно, а полнота оценивает, какая доля токенов, действительно являющихся границами ЭДЕ, была предсказана верно. Чтобы объединить эти метрики, вводится гармоническое среднее точности и полноты – F-мера [17]. Для сравнения сегментаторов обычно анализируются все эти три метрики.

Однако, оценка построенного дерева риторической структуры относительно “золотого стандарта” является более сложной задачей. Дэниэл Марку в [18] предложил адаптировать процедуру Parseval, изначально предназначенную для оценки синтаксической структуры в виде дерева составляющих, для оценки дерева риторической структуры. Адаптированную процедуру в литературе называют RST-Parseval, и она рассчитывает оценки для структуры дискурса без меток (S, Span), для структуры с отмеченными ядрами и сателлитами (N, Nuclearity), с

отмеченными отношениями (R, Relation) или для полностью размеченной структуры (F, Full).

В 2017 году было проведено исследование [19], цель которого заключалась в оценке прогресса в области парсинга риторической структуры. Исследование показало, что в работах, посвященных этой теме, наблюдается несоответствие процедур оценки результатов, и процент улучшения, приведенный в последних работах по сравнению с предыдущими, на самом деле значительно меньше. Авторы работы говорят о том, что исследователям в этой области необходимо пересмотреть и стандартизировать процедуру оценки результатов, чтобы избежать таких несоответствий в будущем.

Дискурсивный корпус для русского языка

Как уже отмечалось ранее, получение хороших результатов при построении дерева дискурса практически невозможно без применения машинного обучения с учителем, а для этого важным условием является наличие размеченного корпуса.

В английском языке используется корпус RST Discourse Treebank, состоящий из 385 статей из Wall Street Journal. При этом данные разбиты на обучающую выборку (347 статей) и тестовую выборку (38 статей). Для других языков такие корпуса также разрабатываются: Potsdam Commentary Corpus для немецкого языка (176 текстов), RST Spanish Treebank для испанского языка (267 текстов), RST Basque Treebank для баскского языка (60 текстов) и другие.

Однако, для русского языка до недавнего времени едва ли не единственным размеченным дискурсивным корпусом на русском языке являлся корпус устных текстов, созданный А.А. Кибриком и его коллегами (корпус «Рассказы о сновидениях») [1]. Данный корпус создавался с целью исследования особенностей устного дискурса у здоровых детей и детей с невротическими расстройствами, и не может быть использован для разработки автоматических систем анализа текстов.

В 2016 году началась разработка открытого корпуса текстов с разметкой на основе TPC для русского языка, были определены принципы разметки и используемый набор отношений [20]. На сегодняшний день корпус уже содержит 333 текста, представляющих собой новостные и научные тексты, а также тексты из блогов.

В ходе разработки был изменен начальный набор отношений, предложенный Манном и Томпсон, и для корпуса определено 11 одноядерных отношений и 6 мультиядерных.

Автоматическое аннотирование текста

Существуют различные подходы к классификации методов автоматического аннотирования. Но чаще всего, когда говорят о видах автоматического аннотирования, в качестве

Impact Factor:

ISRA (India) = 4.971
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 0.126
ESJI (KZ) = 8.716
SJIF (Morocco) = 5.667

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

критерия классификации берется способ построения текста аннотации. В этом случае выделяют извлекающее и генерирующее аннотирование.

При использовании извлекающих методов аннотирования из исходного текста выделяются наиболее важные предложения. При этом данные предложения не обрабатываются, и извлекаются в таком порядке, в котором они представлены в тексте. Результатом генерирующих методов является аннотация, включающая в себя слова и фразы, которые отличаются от тех, которые присутствовали в исходном тексте. Таким образом, такая аннотация состоит из идей и концепций, взятых из исходного документа, но они реинтерпретированы и представлены в другой форме [21].

Извлекающие методы

Для извлекающих методов можно выделить несколько отдельных подзадач, которые они решают: промежуточное представление текста, оценка каждого предложения и выбор предложений для аннотации [22]. Для промежуточного представления может использоваться набор характеристик, описывающих каждое предложение. Такими характеристиками могут быть, например, номер предложения в тексте, наличие в нем часто встречающихся в документе слов, степень сходства с другими предложениями и т.д. Более поздние методы извлекающего аннотирования применяют машинное обучение для определения степени значимости (веса) каждой характеристики, в противовес ранним работам, где веса выбирались авторами вручную.

Очевидно, что извлекающее аннотирование имеет свои ограничения [23]:

- аннотация может состоять только из слов и фраз, встречающихся в исходном тексте;
- текст аннотации может получиться несвязным;
- текст аннотации может исказить факты и ввести в заблуждение (в частности, если выбранные предложения приводят к неправильному разрешению анафоры).

Для решения последних двух проблем предлагаются различные способы улучшения связности и фактической корректности генерируемых аннотаций, в то время как первое ограничение связано с самой природой извлекающих методов аннотирования. Однако наличие этого ограничения вовсе не означает, что извлекающие методы непригодны для решения поставленной задачи.

Так, в [24] автор проанализировал 300 аннотаций к новостным текстам и обнаружил, что в аннотациях, составленных людьми, значительная часть предложений (81%) дословно взяты из исходного текста, а в [25] показано, что

для корпуса DUC в среднем 70% предложений в аннотациях полностью или частично появляются в исходном тексте. В работе [26] авторы говорят о том, что в среднем 91% используемых в аннотациях слов встречается в самом тексте. Все эти наблюдения говорят о том, что несмотря на ограничения извлекающих методов аннотирования, их можно успешно использовать для создания качественных аннотаций.

Генерирующие методы

Первые генерирующие методы использовали полуавтоматические методы определения основных идей документов – создавались специальные заготовки-шаблоны, пропуски в которых заполнялись на основе информации из документа.

С развитием методов глубокого обучения рос и интерес к их применению в области автоматического аннотирования. По сравнению с другими методами, они позволяют добиваться лучших результатов с меньшим участием человека при условии наличия большого количества данных для обучения.

Для английского языка есть достаточно большие корпуса данных, чтобы экспериментировать с методами глубокого обучения – это корпус CNN/DailyMail, содержащий примерно 312 тысяч пар новостная статья–аннотация, и корпус Gigaword, содержащий примерно 4 млн. пар новостная статья–заголовки.

Однако, у них есть и некоторые недостатки: в частности, оба набора данных содержат только новостные статьи, которые придерживаются определенного стиля, в связи с этим системы, обученные на таких корпусах, могут не подойти для аннотирования текстов другого жанра. Помимо этого, корпус Gigaword критикуется за использование в качестве аннотации лишь заголовка статьи, а аннотации CNN/DailyMail – за довольно низкий уровень абстракции [27].

На сегодняшний день наибольшей популярностью пользуется модель seq2seq, и большинство работ в области генерирующего аннотирования предлагают различные вариации этой модели. На данный момент лучших результатов на наборах данных CNN/DailyMail и Gigaword добилась разработка Microsoft – для ряда задач из областей понимания естественного языка и генерации естественного языка они применили свою предварительно обученную языковую модель UniLM [28].

Несмотря на большой успех моделей глубокого обучения, у существующих методов есть некоторые ограничения [29]:

- они не справляются с документами, длина которых превышает несколько тысяч слов, в связи с высокими требованиями к памяти;

Impact Factor:

ISRA (India) = 4.971
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 0.126
ESJI (KZ) = 8.716
SJIF (Morocco) = 5.667

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

– они не способны обучаются на небольших наборах данных, так как имеют большое количество параметров;

– такие модели медленно обучаются в связи со сложностью архитектуры.

Также аннотации, полученные в результате работы таких систем, могут страдать от повторяющихся фраз и смысловых ошибок.

Так, в работе [30] авторы рассматривают пять передовых систем, использующих модель кодер-декодер, и сосредотачиваются на исследовании того, как в них происходит объединение информации из нескольких предложений в одно. Проводится оценка объединенных предложений по двум параметрам: верность оригиналу и грамматическая правильность. Согласно результатам исследования, полученные предложения чаще всего грамматически верны (в среднем 74,8% от выборки грамматически верны), но далеко не всегда верны оригиналу, то есть искажают смысл (в среднем 61,7% от выборки верны оригиналу). Чаще всего искажение фактов связано с подменой сущностей.

Теория риторической структуры в задаче аннотирования текста

Помимо простого извлечения предложений в извлекающих методах возможно также их редактирование. В частности, сжимающие методы включают в аннотацию предложения, которые модифицируются путем удаления некоторых слов. Результирующие аннотации часто содержат больше информации, чем при использовании извлекающих методов, так как возможно удаление менее важных частей предложения и остается место для более важной информации, которая в ином случае может не оказаться в аннотации в связи с ограничениями на ее длину [31]. Чаще всего для сжатия отсекаются ветви синтаксического и дискурсивного деревьев.

Так как риторическая структура – это один из способов представления дискурса текста, то ее применение в задаче автоматического аннотирования текста может значительно увеличить связность сгенерированной аннотации.

Отсечение ветвей дерева дискурса применяется, например, в работе [32]. В ней авторы формулируют задачу аннотирования как задачу комбинаторной оптимизации и составляют набор ограничений в терминах линейного программирования.

В работе [33] задача автоматического аннотирования также представлена как задача линейного программирования. В своей модели авторы вводят несколько разновидностей ограничений: грамматические ограничения, анафорические ограничения и ограничения на длину. Риторическая и синтаксическая структуры используются для сжатия предложений с сохранением их грамматической корректности и

связности. При этом авторы отмечают, что использовали риторическую структуру только на уровне предложений, так как их эксперименты с использованием риторической структуры на уровне всего текста не привели к заметным улучшениям. Анафорические ограничения вводятся для решения проблемы появления местоимений без их antecedентов: в системе принимается решение либо о замене местоимения на его antecedent, либо о включении в аннотацию дополнительного предложения.

В [34] рассмотрен еще один вариант использования риторической структуры для автоматического аннотирования текста – это деление текста с ее помощью на отдельные темы. Это деление основывается на определении наиболее связанных предложений текста и анализе отношений topic-shift (резкая смена темы) и topic-drift (плавный переход к другой теме). Для каждой выделенной темы выделяются наиболее важные предложения, и аннотация получается путем их комбинирования.

Риторическая структура может также применяться для методов с использованием нейронных сетей. В работе [35] предлагается улучшить модель с использованием предобученной языковой модели BERT, применение которой позволило достичь отличных результатов для множества различных задач по обработке естественного языка, в том числе и извлекающего аннотирования. В силу особенности обучения BERT, эта модель не может хорошо захватывать зависимости между далеко расположенными предложениями. Предлагаемая модель автоматического аннотирования, DiscoBert, рассматривает в качестве претендентов на попадание в аннотацию не целые предложения, а ЭДЕ, а также авторы вводят понятия двух графов: графа TPC и графа кореферентности. DiscoBert сначала кодирует ЭДЕ при помощи модели BERT, а затем использует графовую сверточную нейронную сеть для захвата зависимостей между далеко расположенными дискурсивными единицами на основе построенных графов.

Заключение

В данной статье были рассмотрены основные принципы теории риторической структуры, способы построения дерева риторической структуры текста. Также были рассмотрены существующие подходы к решению задачи автоматического аннотирования, были выявлены их проблемы и были рассмотрены способы применения теории риторической структуры для решения выявленных проблем.

На основе проведенной работы можно сделать следующие выводы:

Impact Factor:

ISRA (India) = 4.971
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
ПИИЦ (Russia) = 0.126
ESJI (KZ) = 8.716
SJIF (Morocco) = 5.667

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

– генерирующие методы автоматического аннотирования набирают популярность благодаря развитию методов глубокого обучения;

– и извлекающие, и генерирующие методы могут страдать от искажения фактов и некоторой несвязности полученного текста;

– теория риторической структуры может применяться в методах автоматического аннотирования для создания более связного текста.

References:

1. Kibrik, A., & Podlesskaya, V. (2009). *Rasskazy o snovideniyakh: Korpusnoye issledovaniye ustnogo russkogo diskursa*. (p.736). Moskva: Yazyki slavyanskikh kul'tur.
2. Mann, W.C., & Thompson, S.A. (1988). Rhetorical structure theory: Toward a functional theory of text organization *Text-interdisciplinary Journal for the Study of Discourse*. Walter de Gruyter, Berlin/New York. Vol. 8, № 3, pp. 243–281.
3. Mann, W.C., & Matthiessen, C.M.I.M., Thompson S.A. (1992). *Rhetorical Structure Theory and Text Analysis Discourse Description: Diverse Linguistic Analyses of a Fund Raising Text*. (pp.39-78). Amsterdam: Benjamins.
4. Marcu, D. (2000). The rhetorical parsing of unrestricted texts: a surface-based approach *Computational Linguistics*. Vol. 26, № 3, pp. 395–448.
5. Sabinin, O., & Trevgoda, S. (2008). Formalizaciya procedury postroeniya diskursnoj struktury tekhnicheskogo teksta *Mezhdunarodnaya konferenciya po myagkim vy`chisleniyam i izmereniyam, Vol. 1*, pp.198–201.
6. Sabinin, O., & Trevgoda, S. (2008). Texnologiya avtomaticheskogo referirovaniya texnicheskogo teksta. *Izvestiya Sankt-Peterburgskogo gosudarstvennogo e`lektrotexnicheskogo universiteta LE`TI, № 7*, pp. 25–34.
7. Trevgoda, S., & Sabinin, O. (2008). Sistema avtomaticheskogo referirovaniya texnicheskogo teksta. *Pribory i sistemy`. Upravlenie, kontrol`, diagnostika, № 1*, pp. 23–26.
8. Soricut, R., & Marcu, D. (2003). *Sentence Level Discourse Parsing using Syntactic and Lexical Information*. Proceedings of the 2003 Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics, pp. 228–235.
9. Joty, S., Carenini, G., & Ng, R.T. (2015). CODRA: A Novel Discriminative Framework for Rhetorical Analysis *Computational Linguistics*. Vol. 41, № 3, pp. 385–435.
10. Li, J. (2019). *Neural Discourse Segmentation Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence*. (pp. 6539–6541). California: International Joint Conferences on Artificial Intelligence Organization.
11. Lin, X., et al. (2019). *A Unified Linear-Time Framework for Sentence-Level Discourse Parsing*. Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. (pp.4190–4200). Stroudsburg, PA, USA: Association for Computational Linguistics.
12. Wang, Y., Li, S., & Yang, J. (2018). *Toward Fast and Accurate Neural Discourse Segmentation*. Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. (pp.962–967). Stroudsburg, PA, USA: Association for Computational Linguistics.
13. Huang, Z., Xu, W., & Yu, K. (2015). Bidirectional LSTM-CRF Models for Sequence Tagging.
14. Li, J., Sun, A., & Joty, S. (2018). SEGBOT: A generic neural text segmentation model with pointer network *IJCAI International Joint Conference on Artificial Intelligence*. Vol. 2018-July, pp. 4166–4172.
15. Vinyals, O., Fortunato, M., & Jaitly, N. (2015). *Pointer Networks*. Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 2. (pp. 2692–2700). Cambridge, MA, USA: MIT Press.
16. Wang, Y., Li, S., & Wang, H. (2017). *A Two-Stage Parsing Method for Text-Level Discourse Analysis* Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). (pp. 184–188). Stroudsburg, PA, USA: Association for Computational Linguistics. Vol. 2.

Impact Factor:

ISRA (India) = 4.971
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
PIHHI (Russia) = 0.126
ESJI (KZ) = 8.716
SJIF (Morocco) = 5.667

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

17. Müller, A.C., & Guido, S. (2016). *Introduction to Machine Learning with Python: A Guide for Data Scientists*. (p.400). O'Reilly Media.
18. Marcu, D. (2000). *The Theory and Practice of Discourse Parsing and Summarization*. (p.248). MIT Press.
19. Morey, M., Muller, P., & Asher, N. (2017). *How much progress have we made on RST discourse parsing? A replication study of recent results on the RST-DT* Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. (pp.1319–1324). Stroudsburg, PA, USA: Association for Computational Linguistics.
20. Pisarevskaya, D., et al. (2017). *Towards building a discourse-annotated corpus of Russian Computational Linguistics and Intellectual Technologies*. Proceedings of the International Conference "Dialogue 2017." pp. 194–204.
21. Shkurina, M., & Sabinin, O. (2018). An Overview and Analysis of Automatic Text Summarization Methods. *ISJ Theoretical & Applied Science*. Vol. 68, № 12, pp. 282–286.
22. Nenkova, A., & McKeown, K. (2012). *A Survey of Text Summarization Techniques Mining Text Data*. (pp.43-76). Boston, MA: Springer US.
23. Shkurina, M., & Sabinin, O. (2019). Comparative Analysis of Extractive Text Summarization Methods for Texts in Russian Language. *ISJ Theoretical & Applied Science*, Vol. 74, № 06, pp. 164–169.
24. Jing, H. (2002). Using Hidden Markov Modeling to Decompose Human-Written Summaries *Computational Linguistics*, Vol. 28, № 4, pp. 527–543.
25. Copeck, T., & Szpakowicz, S. (2004). Vocabulary Agreement Among Model Summaries And Source Documents Proceedings of the Document Understanding Conference (DUC'04).
26. Verma, R., & Lee, D. (2018). Extractive Summarization: Limits, Compression, Generalized Model and Heuristics *Computación y Sistemas*. Vol. 21, № 4, pp. 787–798.
27. Koupae, M., & Wang, W.Y. (2018). WikiHow: A Large Scale Text Summarization Dataset.
28. Dong, L., et al. (2019). Unified Language Model Pre-training for Natural Language Understanding and Generation.
29. Dong, Y. (2018). *A Survey on Neural Network-Based Summarization Methods* [Electronic resource]. Retrieved 2019, from <http://arxiv.org/abs/1804.04589>
30. Lebanoff, L., et al. (2019). *Analyzing Sentence Fusion in Abstractive Summarization Proceedings of the 2nd Workshop on New Frontiers in Summarization*. (pp.104–110). Stroudsburg, PA, USA: Association for Computational Linguistics.
31. Yao, J., Wan, X., & Xiao, J. (2017). Recent advances in document summarization Knowledge and Information Systems. *Springer London*. Vol. 53, № 2, pp. 297–336.
32. Kikuchi, Y., et al. (2014). *Single Document Summarization based on Nested Tree Structure* Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). (pp.315–320). Stroudsburg, PA, USA: Association for Computational Linguistics.
33. Durrett, G., Berg-Kirkpatrick, T., & Klein, D. (2016). *Learning-Based Single-Document Summarization with Compression and Anaphoricity Constraints* Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). (pp.1998–2008). Stroudsburg, PA, USA: Association for Computational Linguistics.
34. Schrimpf, N.M. (2018). *Using Rhetorical Topics for Automatic Summarization* Proceedings of the Society for Computation in Linguistics (SCiL) 2018, pp. 125–135.
35. Xu, J., et al. (2019). *Discourse-Aware Neural Extractive Model for Text Summarization* [Electronic resource]. Retrieved 2019, from <http://arxiv.org/abs/1910.14142>