

УДК 004.912

doi: 10.15622/rcai.2025.021

**АВТОМАТИЧЕСКАЯ КЛАССИФИКАЦИЯ
АРГУМЕНТОВ НА ОСНОВЕ СИСТЕМАТИЗАЦИИ
МОДЕЛЕЙ РАССУЖДЕНИЯ Д. УОЛТОНА¹**

И.Р. Ахмадеева (*i.r.akhmadeeva@iis.nsk.su*)

Ю.А. Загоруйко (*zagor@iis.nsk.su*)

И.С. Кононенко (*irina_k@cn.ru*)

А.С. Серый (*alexey.seryj@iis.nsk.su*)

Е.А. Сидорова (*lsidorova@iis.nsk.su*)

Институт систем информатики им. А.П. Ершова СО РАН,
Новосибирск

Статья посвящена применению трансформерных моделей-энкодеров при разработке методов автоматической классификации аргументов. Представлена категоризация схем Д. Уолтона, включающая четыре классификатора, соответствующих различным уровням или аспектам аргументативной структуры. Были исследованы два подхода к решению задачи мультиклассовой классификации: (1) разработка классификатора для предсказания схемы аргумента и (2) разработка классификатора, предсказывающего схему и

¹ Работа выполнена при финансовой поддержке РНФ (проект № 23-11-00261, <https://rscf.ru/project/23-11-00261/>).

категорию аргумента. Для получения векторных представлений использовалась модель *ru-en-RoSBERTa*. Эксперименты проводились на трех корпусах аннотированных аргументов: русскоязычном корпусе ArgNetSC и двух англоязычных корпусах Agraucaria и NLAS (корпус автоматически сгенерированных аргументов). Наилучшие результаты на русскоязычном корпусе составили 41,3% F1-меры. Результаты по отдельным категориям (классам) аргументов – от 60% до 89%.

Ключевые слова: анализ аргументации, классификация аргументов, мультиклассовая классификация, категоризация схем Уолтона, трансформерная модель.

Введение

Теоретические и практические исследования аргументации опираются на данные о фактическом использовании аргументации в коммуникативной практике. В последнее время набирает обороты работа по получению таких данных, и прежде всего, – по созданию аннотированных корпусов реального аргументативного дискурса, что обусловлено во многом требованиями методов машинного обучения для автоматизированной обработки текста. Анализ данных, в свою очередь, базируется на типовых моделях аргументации – представленных преимущественно в виде схем и таксономий схем, специализированных для различных типов дискурса.

Таксономия схем аргументации Дугласа Уолтона [Walton et al., 2008, 2016] представляет собой эмпирически ориентированную классификацию схем, основанную на изучении очевидных конвенций аргументативной практики. На другом конце спектра находится Периодическая таблица аргументов Дж. Вагеманса [Wagemans, 2016]: она базируется на множественных априорных критериях, разработанных для исчерпывающего описания всех возможных комбинаций различных характеристик аргумента. Существуют и другие альтернативы, имеющие свои собственные преимущества и недостатки: [Feng et al., 2011], [Lawrence et al., 2016], [Musi et al., 2016], [Liga et al., 2020]. Авторы [Visser et al., 2021] аннотировали предвыборные дебаты с использованием схем Уолтона и таблицы Вагеманса. Исследование [Bezou-Vrakatseli et al., 2021] демонстрирует потенциальную совместимость двух подходов к классификации схем и выдвигает идею объединения их сильных сторон. Однако идея гибридной классификации до сих пор не получила широкого практического применения, более популярными остаются эмпирические модели, такие как модель Д. Уолтона.

Целью данной работы является разработка методов автоматической классификации аргументов, размеченных в соответствии с моделью Д. Уолтона в русскоязычных текстах научной коммуникации.

Для достижения поставленной цели в рамках данной работы были сформулированы следующие вопросы исследования.

RQ1. Какое качество мультиклассовой классификации аргументов в процессе анализа текстов научной коммуникации на русском языке можно получить с использованием нейросетевого подхода? Количество классов определяется количеством схем аргументов Уолтона, используемых при аннотировании наборов данных.

RQ2. Эффективно ли применение дополнительной систематизации при автоматической классификации аргументов? Под систематизацией в данном случае будет пониматься категоризация, объединяющая модели аргументов в группы по значимым признакам.

1. Обзор методов классификации аргументов

Задача классификации аргументов замыкает цепочку подзадач интеллектуального анализа аргументации (Argument Mining, AM) и может рассматриваться как задача мультиклассовой классификации аргументативных отношений (МКА) для заданных наборов посылок и тезисов. Трансформерные архитектуры языковых моделей с последующим дообучением (Supervised fine-tuning, SFT) на сегодняшний день наиболее эффективны для задач анализа текста. Однако этот подход требует репрезентативных наборов обучающих данных, что в случае МКА означает наличие представительного набора аннотированных аргументов для каждого класса из заданного классификатора.

Появление ресурсов, аннотированных схемами аргументации (таких как корпус Agraucaria [Reed et al., 2008]) позволило сделать первые шаги по автоматическому выявлению схем аргументации с применением моделей классификации [Walton, 2011]. В дальнейшем исследования в значительной степени опирались на метод SVM и нейронные сети.

В [Feng et al., 2011] в рамках решения задачи реконструкции энтимем в качестве первого этапа проводится классификация аргументов по пяти наиболее частотным схемам Уолтона. При этом зафиксирована точность 0,63–0,91 в классификации «один против всех» и 0,80–0,94 в попарной классификации. При обучении использовался корпус Agraucaria, в котором выбирались аргументативные сегменты, реализующие пять наиболее распространенных схем аргументации, и классификатор обучался как по признакам, специфичным для каждой отдельной схемы, так и по ряду общих лингвистических признаков.

В подходе [Lawrence, et al., 2015] идентифицируются отдельные компоненты схем, которые затем группируются в экземпляры схем. Здесь рассматриваются только две схемы (*From Expert Opinion* и *From Positive Consequences*), а классификаторы обучаются идентифицировать их от-

дельные компоненты, посылки и выводы. Учет признаков отдельных типов этих компонент дал F1-меру от 0,75 до 0,93 при идентификации хотя бы одной составляющей схемы.

Исследование [Stab et al., 2014], проведенное на материале 90 студенческих эссе, выделяет компоненты аргумента в многоклассовой классификации с помощью алгоритма SVM (классы: *Major Claim*, *Claim*, *Premise*, *None*) и признаков различных типов (структурные, лексические, синтаксические, индикаторные, контекстные). Получены $F1 = 0,73$ для выделения компонентов аргумента и $0,72$ для обнаружения отношений в аргументе.

Исследование [Pimenov et al., 2024], проведенное на базе корпуса ArgNetSC, применяет классические методы машинного обучения – метод опорных векторов (SVM) и многослойный перцептрон (MLP) – для анализа 50 научных статей. Решается задача бинарной классификации для трех самых частотных типов аргументов: *From Part to Whole* ($F1 = 0,64$), *From Verbal Classification* ($F1 = 0,68$), *From Correlation to Cause* ($F1 = 0,64$).

Такие методы, как рекуррентные нейронные сети, сверточные нейронные сети и блоки долговременной и кратковременной памяти (LSTM) сыграли решающую роль во включении контекстных данных в процессы машинного обучения [Srivastava et al., 2022]. [Galassi et al., 2018] применяют LSTM для лучшего прогнозирования взаимосвязей компонентов в сложных структурах аргумента. Преодоление известных ограничений SVM и нейронных сетей, таких как необходимость разработки широкого набора признаков и трудности в захвате дальних зависимостей в тексте, связывают с появлением моделей на основе Transformer и особенно BERT: [Vaswani et al., 2017] и [Devlin et al., 2019].

2. Систематизация схем аргументов на основе модели Д. Уолтона

Д. Уолтон с коллегами неоднократно пересматривали первоначально предложенную таксономию схем. В [Walton et al., 2008] представлена система, состоящая из трех основных категорий. В последней версии системы [Walton et al., 2016] классическое различие между зависимыми от источника и независимыми от источника аргументами дает критерий для первой дихотомии. Зависимые от источника аргументы далее делятся на «эпистемические аргументы» и «практические аргументы», а первые подразделяются на те, которые заключаются в применении правил к случаям, и те, которые извлекают правила или сущности («аргументы открытия»). Авторы допускают, что одним из путей развития является ввод дополнительных классификаторов, которые позволят произвести “скрещивание” новой и существующей классификаций.

Отмечая сложности аннотирования на основе таксономии схем Уолтона, исследователи [Сидорова и др., 2024] обосновали необходимость дальнейшей систематизации схем аргументации и предложили их многоаспектную классификацию [Koponen et al., 2023] (табл. 1). Выбор данного классификатора для проведения экспериментов связан с тем, что, во-первых, он основан на компендиуме Д.Уолтона и рассматривает достаточно большое количество схем аргументов, во-вторых, имеющиеся русскоязычные корпусы имеют согласованную с этим классификатором разметку, и, в-третьих, группы схем, выделяемых в многоаспектном классификаторе, зависят только от формы аргумента и не требуют никаких дополнительных данных.

Таблица 1

Типология схем аргументации

Основное отношение	Тип заключения	
	Практический	Теоретический
Гипер-Гипонимия	К действию	Устройство реальности
Элемент-множество	К цели	Установление реальности
Казуальность	К обязательству	
Коммуникация	Зависимость от источника аргумента	
Кондициональность	Внешний	Внутренний
Корреляция	От знания	От классификации
Меронимия	От цели	От объяснения
Аналогия	От ценности	От определения
Авторитетность	От человека	От факта
Способ	Направление атаки	
Противоречие	Нет атаки	На источник
	На тезис	На аргумент

Представленная категоризация позволяет настроить четыре разных классификатора и вычислить конечный тип аргумента на основании пересечения данных признаков.

3. Наборы данных

Для экспериментального исследования использовались три источника данных, основные характеристики которых представлены в табл. 2.

Таблица 2

Характеристики датасетов

Набор данных	Количество аргументов	Количество схем
Araucaria	730 (1746)*	17
NLAS	1893	20
ArgNetSC	9178	42

Выбор источников обусловлен общей для всех наборов данных разметкой текста с помощью схем аргументации Д. Уолтона. Из всех найденных наборов данных, с разметкой схемами Уолтона, в наше исследование не вошел только датасет Ethix [Bezou-Vrakatseli et al., 2024], поскольку утверждения, вошедшие в его состав, не составляют связного текста, а являются компиляцией аргументов, в то время как нашей задачей является классификация аргументов в тексте. Помимо этого, поддерживаемые или опровергаемые тезисы представлены не в явном виде, а в форме вопросов (*Would the world be a better place without humans?*) и в разметке не содержится указаний на то, какую из двух точек зрения доказывает каждый аргумент и, как следствие, невозможно осуществить промежуточную классификацию аргумента по признаку направление атаки.

Корпус Aгаucaria содержит англоязычные тексты из материалов газет и судебных дел; всего размечено 1746 аргументов, однако схема указана только для 730 из них. Ресурс характеризует высокая степень несбалансированности: для некоторых схем в корпусе имеется менее пяти примеров (*Inconsistent Commitment, Falsification of Hypothesis, Exceptional Case, Fear Appeal, Popular Practice*).

Англоязычная часть корпуса NLAS [Ruiz-Dolz et al., 2024] представляет 50 тематик, в которых автоматически сгенерированы 1893 аргумента с использованием 20 наиболее распространенных схем Уолтона; для NLAS характерна сбалансированность: имеется 75-100 примеров на каждую схему.

Корпус ArgNetSC [Ilin et al., 2021]) – русскоязычный корпус текстов, относящихся к области научной коммуникации. Тексты снабжены разметкой а) аргументов в соответствии с моделью Д. Уолтона – всего около 9 тыс. размеченных аргументов; б) классов аргументов. Корпус включает 286 текстов различных научных и научно-популярных жанров. Тексты имеют в среднем объем 3,5 тыс. токенов, средний объем комментария к ним – 2-5 предложений. На рис. 1 приведена статистика встречаемости аргументов каждого класса в корпусах.

Из рисунка видно, что классы остаются несбалансированными. При экспериментальных исследованиях классы с малым количеством встречаемости были исключены из рассмотрения, а аргументы, относящиеся к этим классам отнесены к другим классам в соответствии с их семантикой. Так, классы «К цели» и «К действию» не рассматривались, вместо этого использовался их родительский класс: «Практический аргумент», а схемы класса «К обязательству» перенесены в «Установление реальности».




Рис. 1. Классы аргументов в корпусе ArgNetSC

4. Экспериментальное исследование

Датасеты с описанными выше свойствами позволяют провести следующие экспериментальные исследования:

- Обучение классификации англоязычных текстов на сгенерированных аргументах (корпусе NLAS) и тестирование на “естественных” текстах корпуса Araucaria (на материале газет и судебных дел).
- Обучение модели классификации аргументов и сравнение качества классификации с учетом и без учета дополнительной систематизации.

4.1. Архитектура эксперимента

В данной работе были исследованы два подхода к решению задачи мультиклассовой классификации аргументов: (1) классификация с использованием дообученной трансформерной модели и (2) классификация на основе систематизации схем Уолтона.

Для дообучения была использована модель ru-en-RoSBERTa [Snegirev et al., 2025], которая основана на модели ruRoBERTa [Zmitrovich et al., 2024] и является универсальной моделью для построения текстовых эмбедингов для русского языка. Выбор данной модели также обусловлен тем, что по результатам предварительных экспериментов она продемонстрировала лучшее качество в задаче классификации схем аргументации по сравнению с другими русскоязычными и мультиязычными моделями, такими как BERTa, ruRoBERTa, mBERT.

В рамках данного подхода были предложены два способа интеграции информации о категориях схем аргументации в процесс классификации: многозадачное обучение и регуляризация эмбедингов на основе категорий. Для их проверки были созданы классификаторы, реализующие один из методов или их комбинацию, которые сравнивались с базовой моделью на основе трансформерной архитектуры RoBERTa:

1. RoBERTa-sch – базовый многоклассовый классификатор по схемам аргументации.
2. RoBERTa-sch+cls-MT – модель, одновременно предсказывающая схему аргумента и его категории в рамках каждого из четырех классификаторов, обученная в многозадачном режиме.
3. RoBERTa-sch+cls-Reg – модификация модели (1), в которой векторные представления аргументов, принадлежащих одному классу, должны быть близки в векторном пространстве, что достигается с помощью контрастивной функции потерь.
4. RoBERTa-sch+cls-MT-Reg – модель, использующая обе предложенные стратегии.

Задача классификации аргументов в соответствии с систематизацией схем Уолтона проще детализированной классификации по конкретным схемам, поскольку количество категорий схем меньше, что обеспечивает более равномерное представление каждой категории в обучающей выборке. Однако задача усложняется тем, что один аргумент может одновременно принадлежать нескольким категориям, что требует решения проблемы классификации по нескольким меткам (multi-label). Для решения данной задачи была разработана архитектура из четырех классификаторов, обученных в режиме многозадачного обучения с использованием функции потерь на основе бинарной кросс-энтропии (Binary Cross Entropy), которая позволяет независимо оценивать принадлежность текста к каждой категории.

Для компенсации дисбаланса как в распределении схем, так и в распределении их категорий применялись специализированные функции потерь: для классификации схем – фокусная функция потерь (Focal Loss), уменьшающая влияние часто встречающихся и легко распознаваемых примеров, для классификации категорий – бинарная кросс-энтропия с весовой корректировкой, где каждой категории назначался вес, обратно пропорциональный частоте ее встречаемости.

4.2. Результаты экспериментов

Для оценки качества модели на корпусе ArgNetSC использовалась перекрестная проверка (cross-validation) с разбиением на 5 частей. Внутри каждой обучающей выборки дополнительно выделялась валидационная выборка (20%) для подбора гиперпараметров и применения ранней остановки. Результаты усреднялись по всем 5 частям.

Небольшой объем корпуса Araucaria не позволил использовать его для полноценного обучения моделей. Единицы примеров для некоторых аргументативных схем делает невозможным их корректную классификацию и обобщение моделью. В связи с этим была применена стратегия переноса обучения (transfer learning): в соответствующем эксперименте обучение осуществлялось на автоматически сгенерированном корпусе NLAS, а тестирование – на корпусе Araucaria. При этом на валидационной части NLAS получено значение F1 = 99%.

В табл. 3 представлены значения взвешенных метрик точности (P), полноты (R) и F1, агрегированные с учетом распределения классов.

Таблица 3

Результаты экспериментов по классификации аргументов

Model	Araucaria			ArgNetSC		
	P	R	F1	P	R	F1
RoBERTa-sch	38,3	18,22	21,63	42,21	43,68	41,3
RoBERTa-sch+cls MT	42,37	25,62	27,38	43,36	42,74	41,23
RoBERTa-sch+cls Reg	37,59	30,1	28,54	43,13	42,01	40,97
RoBERTa-sch+cls MT-Reg	38,73	31,1	28,7	43,41	41,7	40,63

Из таблицы видно, что наилучшие результаты для английского корпуса дает модель RoBERTa-sch+cls-MT-Reg, для которой получены лучшие полнота и F1. Для англоязычного корпуса точность выше, чем полнота, что, возможно, связано с тем, что в обучающей выборке отсутствовали примеры некоторых классов. В целом, результаты на русскоязычном корпусе лучше, что, по-видимому, объясняется тем, что модель для английского языка обучалась на синтезированных данных.

В табл. 4 представлены значения F1-меры для каждой категории многоаспектной классификации.

Таблица 4

Результаты классификации аргументов по дополнительным категориям

Корпус	Основное отношение	Тип заключения	Зависимость от источника аргумента	Направление атаки
Araucaria	17,8	49,6	25,93	86,76
ArgNetSC	61,59	64,02	60,25	89,73

Из таблицы видно, что результаты для русскоязычного корпуса по всем четырем классификаторам значительно лучше, чем для англоязычного.

4.3. Обсуждение результатов

В целом (RQ1) качество классификации не очень высокое. Наблюдается контраст по качеству между синтезированными текстами (99%) и естественными текстами, демонстрирующими значительно более низкие результаты. Одна из возможных причин – дисбаланс классов в русскоязычном корпусе, вторая причина связана с множественностью результата классификации (multi-label) для принятой систематизации.

Анализ и сравнение результатов работы моделей на разноязычных наборах данных показывают, что на текущий момент предлагаемый подход лучше работает для русского языка, что, по-видимому, связано с разным качеством датасетов.

В отношении влияния дополнительной систематизации схем аргументации (RQ2) на результаты классификации можно отметить, что модель демонстрирует положительные результаты для английского языка и в то же время отсутствие значимых результатов для русского языка. В целом можно сделать вывод о полезности применения систематизации в условиях недостаточности обучающих данных.

К причинам ошибок, не связанных с процедурой экспериментов, относятся факторы, которые в целом затрудняют решение задачи АМ:

- Естественной речи свойственно не прямое выражение мыслей, в особенности, в публицистических жанрах. Утверждения, реализующие посылки и заключение аргумента, иногда выражаются косвенным образом, и аннотаторы могут корректно восстановить смысл только в контексте целого графа.
- Ещё одно свойство естественной речи – большое количество энтимем (имплицитность, отсутствие посылки или заключения в явном виде). Значимость этого фактора подтверждается разницей результатов, полученных на синтетически сгенерированном корпусе NLAS и естественном ArgNetSC.
- Из-за диалогового характера взаимодействия в жанре комментариев к аналитическим статьям (часть корпуса ArgNetSC) элементы одного аргумента могут принадлежать разным участникам диалога и быть лексически и синтаксически неполными (эллипсис в комментариях) и неоднородными (неформальность языка комментариев).
- В текстах научной или другой сложной тематики в паре «посылка–заключение», помимо отношений, относящихся к аргументу, могут быть эксплицированы и другие семантические отношения.

Заключение

В работе представлено экспериментальное исследование процедуры автоматической классификации аргументов в соответствии с набором схем Д. Уолтона на основе нейросетевого подхода. Рассмотрены две до-

полнительные стратегии обучения моделей на основе систематизации схем аргументов: многозадачное обучение и регуляризация эмбедингов на базе категорий.

Наилучшие результаты на русскоязычном корпусе достигли 41,3% F1-меры для мультиклассовой классификации по 42 классам. Использование многоаспектной классификации позволило улучшить качество классификации аргументов на англоязычных текстах более, чем на 7%, однако практически не повлияло на качество анализа русскоязычных текстов. В целом качество классификации по отдельным категориям достаточно хорошее – от 60% до 89%.

Дальнейшее развитие подхода может быть связано с развитием систематизации, балансировкой наборов данных и интеграцией с большими языковыми моделями.

Список литературы

- [Сидорова и др., 2024] Сидорова Е.А., Кононенко И.С.. Онтологический анализ приемов аргументации в научном дискурсе // Информационные и математические технологии в науке и управлении. – 2024. – № 3(35). – С. 20-32. – DOI: 10.25729/ESI.2024.35.3.002.
- [Bezou-Vrakatseli et al., 2021] Bezou-Vrakatseli E., Cocarascu O., & Modgil S. Towards an Argument Scheme Classification for Ethical Reasoning // In: CEUR Workshop Proceedings. – 2021. – 3205. – P. 13-17.
- [Bezou-Vrakatseli et al., 2024] Bezou-Vrakatseli E., Cocarascu O., Modgil S. Ethix: A Dataset for Argument Scheme Classification in Ethical Debates // In 27th European Conference on Artificial Intelligence (ECAI). – 2024. – P. 3628-3635. – doi: 10.3233/FAIA240919.
- [Devlin et al., 2019] Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-training of deep bidirectional transformers for language understanding // In Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. – 2019. – Vol. 1. – P. 4171-4186.
- [Feng et al., 2011] Feng V.W., Hirst G. Classifying arguments by scheme // In: The 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies. – 2011. – P. 987-996.
- [Galassi et al., 2018] Galassi A., Lippi M., Torroni P. Argumentative link prediction using residual networks and multi-objective learning // In: Proceedings of the 5th Workshop on Argument Mining. – 2018. – P. 1-10.
- [Ilina et al., 2021] Ilina Daria, Kononenko Irina, Sidorova Elena. On Developing a Web Resource to Study Argumentation in Popular Science Discourse // In Computational Linguistics and Intellectual Technologies: Proceedings of the International Conference “Dialog-2021”. – 2021. – P. 318-327.
- [Kononenko et al., 2023] Kononenko I.S., Sery A.S., Shestakov V.K., Sidorova E.A., Zagorulko Y.A. An Approach to Classifying Walton's Argumentation Schemes // In: Proc. 2023 IEEE XVI International Scientific and Technical Conference Actual Problems of Electronic Instrument Engineering (APEIE), Novosibirsk, 2023. – P. 1540-1545. – doi: 10.1109/APEIE59731.2023.10347573.

- [Lawrence, et al., 2015] Lawrence J., Reed C. Combining argument mining techniques // In Proceedings of the 2nd Workshop on Argumentation Mining. – 2015. – P. 127-136.
- [Lawrence et al., 2016] Lawrence J., Reed C. Argument mining using argumentation scheme structures // In: Proceedings of Computational Models of Argument (COMMA). – 2016. – P. 379-390.
- [Liga et al., 2020] Liga D., Palmirani M. Argumentation schemes as templates? Combining bottom-up and top-down knowledge representation // In: Proc. 20th CMNA workshop. – 2020. – P. 51-56.
- [Musi et al., 2016] Musi E., Ghosh D., Muresan S. Towards feasible guidelines for the annotation of argument schemes // In: Proc. Third Workshop on Argument Mining, ArgMining@ACL, 2016. – P. 82-93.
- [Pimenov et al., 2024] Pimenov I.S., Salomatina N.V. An Automatic Method for Standartizing Argumentative Annotations across Annotators Genres // 2024 IEEE 25th International Conference of Young Professionals in Electron Devices and Materials (EDM). – 2024. – P. 2260-2265. – DOI: 10.1109/EDM61683.2024.10615176.
- [Reed et al., 2008] Reed C., Mochales Palau R., Rowe G., Moens M.F. Language resources for studying argument // In: Proc. 6th conference on language resources and evaluation (LREC 2008). – 2008. – P. 91-100.
- [Ruiz et al., 2024] Ruiz-Dolz R., Tavernier J., Lawrence J., Reed C. NLAS-multi: A multilingual corpus of automatically generated Natural Language Argumentation Schemes, Data in Brief. – 2024. – Vol. 57. – <https://doi.org/10.1016/j.dib.2024.111087>.
- [Snegirev et al., 2025] Snegirev A., Tikhonova M., Maksimova A., Fenogenova A., Abramov A. The Russian-focused embedders' exploration: ruMTEB benchmark and Russian embedding model design // Proceedings of the 2025 Conference of the Nations of the Americas Chapter of the Association for Computational Linguistics: Human Language Technologies (Volume 1: Long Papers) / ed. Chiruzzo L., Ritter A., Wang L. Albuquerque, New Mexico: Association for Computational Linguistics, 2025. – P. 236-254.
- [Srivastava et al., 2022] Srivastava P., Bhatnagar P., Goel A. ArgumentMining using BERT and Self-Attention based Embeddings // 2022 4th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N). – 2022. – <https://doi.org/10.48550/arXiv.2302.13906>.
- [Stab et al., 2014] Stab C. and Gurevych I. Identifying argumentative discourse structures in persuasive essays // in Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). – 2014. – P. 46-56.
- [Vaswani et al., 2017] Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser L., Polosukhin I. Attention is all you need. Advances in neural information processing systems. – 2017. – 30.
- [Visser et al., 2021] Visser J., Lawrence J., Reed C., Wagemans J., Walton D. Annotating argument schemes // Argumentation. – 2021. – 35. – P. 101-139. – doi: 10.1007/s10503-020-09519-x.
- [Walton, 2011] Walton D. Argument mining by applying argumentation schemes // Studies in Logic. – 2011. – 4(1). – P. 38-64.
- [Wagemans, 2016] Wagemans J.H.M. Constructing a Periodic Table of Arguments / Ed. Bondy P., Benacquista L. Argumentation, Objectivity, and Bias, Proc. of the 11th International Conference of the Ontario Society for the Study of Argumentation (OSSA), Windsor, 2016. – P. 1-12.

- [Walton et al., 2008]** Walton D., Reed C., Macagno F. Argumentation schemes. – Cambridge, Cambridge University Press, 2008. – 456 p.
- [Walton et al., 2016]** Walton D., and Macagno F. A Classification System for Argumentation Schemes // Argument & Computation. – 2016. – P. 1-29.
- [Zmitrovich et al.]** Dmitry Zmitrovich, Aleksandr Abramov, Andrey Kalmykov et al. A Family of Pretrained Transformer Language Models for Russian // Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024). – 2024. – P. 507-524.