

Открытый корпус для разрешения корелерентности для русского языка

Егор Будников, Дарья Зверева

АВВУУ, МФТИ

Дарья Максимова

НИУ ВШЭ

План доклада

- Постановка задачи
 - Характеристики корпуса
 - Модель разметки
 - Текущие результаты и дальнейшие действия
-

Постановка задачи

Задача разрешения кореферентности в тексте заключается в определении того, относятся ли два *упоминания* к одной *сущности*.

Упоминание – фраза, ссылающаяся на объект или явление.

Сущность – непосредственно сам объект или явление.

Пример:

Паша спешит на **занятие** **Он** не хочет на **него** опаздывать.

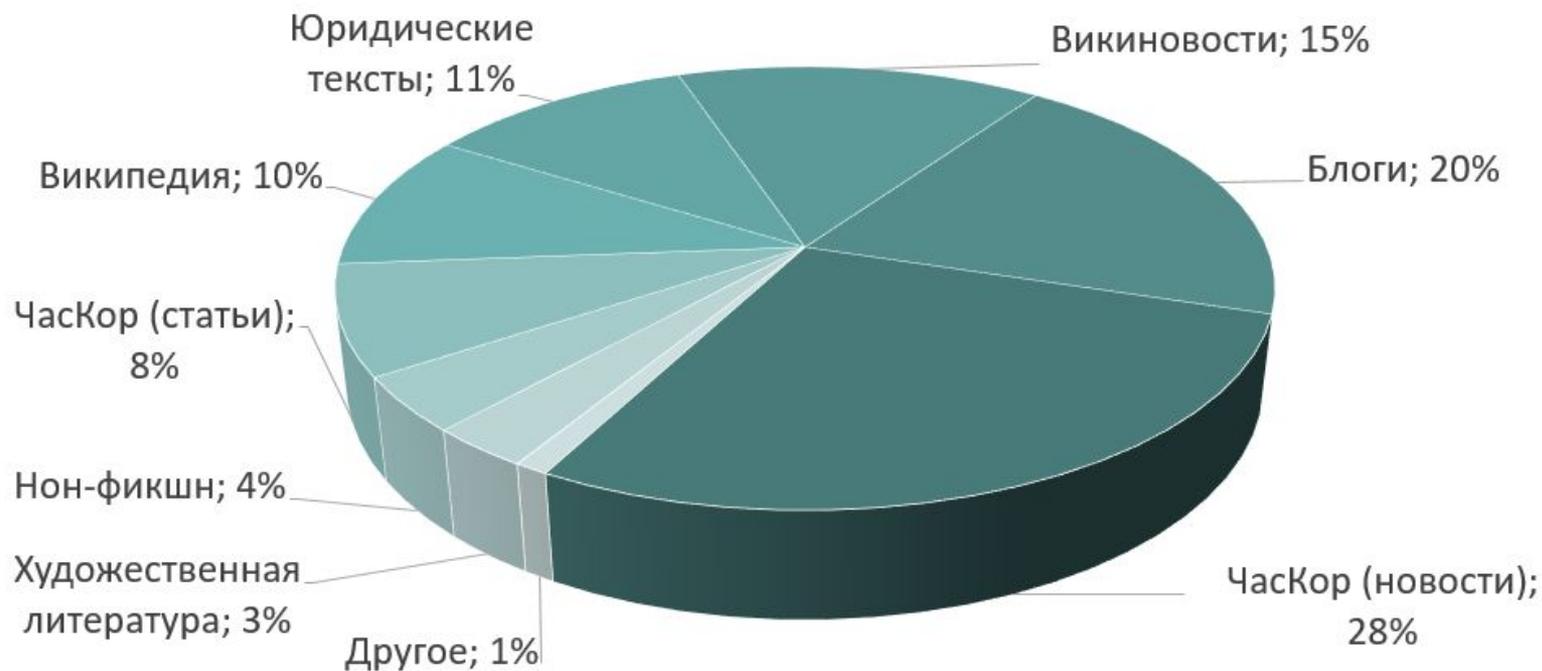
Существующие корпуса

- Message Understanding Conference-6 [Grishman, Sundheim 1996]
 - Английский (318 документов)
 - CoNLL-2012 Shared Task [Pradhan et al. 2012]
 - Английский (2384 документа), Арабский (447), Китайский (1729)
 - Prague Dependency Treebank [Nedoluzhko 2016]
 - Английский, Чешский (50к предложений, >60к связей)
 - RuCor [Toldova et al. 2014]
 - Русский (181 документ)
-

Новый корпус

- Источник текстов: Открытый корпус русского языка (OpenCorpora.org)
 - Размер: 3729 документов
-

Новый корпус: распределение документов



Разметка нового корпуса

- Слои упоминаний
 - Слои кореференциальных цепочек
 - Морфологический слой
 - Семантико-синтаксический слой
 - Эмбединги семантических классов
-

Разметка слоя упоминаний

Источники:

- ABBYY Compeno (автоматическая)
- Разметчики (эталонная)

Формат:

- Идентификатор упоминания
 - Смещение упоминания
 - Длина упоминания
-

Разметка слоя упоминаний

Размечаются:

- Персоны, Локации, Организации, иные именные сущности
Ключевое слово + Идентификатор. Всегда имеют референта
 - Именные группы
Реальные объекты или абстрактные понятия, на которые ссылаются позднее
 - Местоимения и местоименные группы
Те, которые могут иметь референта (кроме негативных, взаимных и возвратных)
-

Разметка слоя упоминаний: интересные случаи

- Возвратные и взаимные местоимения

Вася ходил в магазин. Мальчик купил *себе утюг.

Коля и Катя во всем *друг друга поддерживают.

- Синонимичные названия (псевдонимы)

107-мм пушка образца 1940 года (М-60)

- “Прилагательные”, имеющие референтов

Британская разведка; Североамериканская литература; мой дом;

который смог

Разметка слоя упоминаний: интересные случаи [2]

- Именованные упоминания vs. Неименованные упоминания
Маленький мальчик Вася, который умеет плавать (2 упоминания)
Маленький мальчик, который умеет плавать (1 упоминание)
- Описательные именные группы
Вася признан *самым смелым мальчиком в классе*. Самый смелый мальчик на прошлой неделе снял котенка с дерева.
- Описательные именные группы [2]
Лидером мнений на этой неделе оказался *Петя*. На прошлой неделе им был *Вася*.

Разметка слоя цепочек

Источник:

- Разметчики (эталонная)

Формат:

- Идентификатор упоминания
 - Смещение упоминания
 - Длина упоминания
 - Идентификатор цепочки
-

Разметка слоя цепочек: интересные случаи

- Часть и целое

Петя₁ и Вася₂ одноклассники. Они₃ каждый день ходят в школу вместе. Мальчики₃ живут в соседних подъездах. Петя₁ живет на третьем этаже, а Вася₂ на пятом.

- Описательные именные группы

Лидером мнений₁ на этой неделе оказался Петя. На прошлой неделе им₁ был Вася.

Морфологический слой

Источник:

- OpenCorpora (эталонная)

Формат:

- Идентификатор токена
 - Смещение токена
 - Длина токена
 - Лемма
 - Морфологические теги
-

Семантико-синтаксический слой

Источник:

- ABBYY Compeno (автоматическая)

Формат:

- Смещение токена
 - Токен
 - Смещение родительского токена
 - Идентификатор семантического класса
 - Идентификатор синтаксической парадигмы
-

Эмбединги семантических классов

Источник:

- ABBYY Comreno (обучено на 800М слов)

Формат:

- Идентификатор семантического класса
 - Вектор размерности 200
-

Статус работ

- Разметок упоминаниями хотя бы одним разметчиком — 432 документа
- Разметок упоминаниями двумя разметчиками — 183 текстов
- Сведено разметок упоминаниями — 120 текстов
- Разметок кореференциальными цепочками — 120 текстов

Текущий размеченный корпус лежит тут: <https://goo.gl/U2vTvS>

Статус работ

	<i>Сейчас</i>	<i>Август 2018</i>	<i>Декабрь 2018</i>	<i>Однажды</i>
Текстов	120	400	800	3700
Упоминаний	8700	29К	58К	250К
Упоминаний в корейф. цепочках	6500	22К	44К	200К
Корейф. цепочек	1300	4К	8К	35К

Мера согласия разметок упоминаниями

	<i>Полнота</i>	<i>Точность</i>	<i>F-мера</i>
Верификаторы 1 vs. 2	76.40%	68.50%	72.20%
Верификаторы 1,2 vs. финальная разметка упоминаниями	77.40%	93.70%	84.80%
Авторазметка vs. финальная разметка упоминаниями	94.30%	30.40%	45.90%

Список литературы

1. Anisimovich et al. 2012 — Anisimovich K., Druzhkin K., Minlos F., Petrova M., Selegey V., and Zuev K. (2012). Syntactic and semantic parser based on ABBYY Compro linguistic technologies. In Computational Linguistics and Intellectual Technologies. Papers from the Annual International Conference "Dialogue", vol. 11, pp. 91–103.
 2. Grishman, Sundheim 1996 — Grishman, R., & Sundheim, B. (1996). Message understanding conference-6: A brief history. In COLING 1996 Volume 1: The 16th International Conference on Computational Linguistics (Vol. 1).
 3. Korobov 2015 — Korobov M. (2015). Morphological Analyzer and Generator for Russian and Ukrainian Languages. In: Khachay M., Konstantinova N., Panchenko A., Ignatov D., Labunets V. (eds) Analysis of Images, Social Networks and Texts. Communications in Computer and Information Science, vol 542.
 4. Luo 2005 — Luo, X. (2005, October). On coreference resolution performance metrics. In Proceedings of the conference on Human Language Technology and Empirical Methods in Natural Language Processing (pp. 25-32). Association for Computational Linguistics.
 5. Moosavi, Strube 2016 — Moosavi, N. S., & Strube, M. (2016). Which Coreference Evaluation Metric Do You Trust? A Proposal for a Link-based Entity Aware Metric. In ACL (1)
 6. Nedoluzhko 2016 — Nguy Giang Linh, Michal Novak, Anna Nedoluzhko (2016). Coreference Resolution in the Prague Dependency Treebank. (ÚFAL/CKL Technical Report #TR-2011-43). Prague: Universitas Carolina Pragensis.
 7. Pradhan et al. 2012 — Pradhan, S., Moschitti, A., Xue, N., Uryupina, O., & Zhang, Y. (2012, July). CoNLL-2012 shared task: Modeling multilingual unrestricted coreference in OntoNotes. In Joint Conference on EMNLP and CoNLL-Shared Task (pp. 1-40). Association for Computational Linguistics.
 8. Stepanova et al. 2016 — Stepanova M. E., Budnikov E. A., Chelombeeva A. N., Matavina P. V., Skorinkin D. A. (2016). Information Extraction Based on Deep Syntactic-Semantic Analysis. In Computational Linguistics and Intellectual Technologies. Papers from the Annual International Conference "Dialogue", pp. 721-732.
 9. Toldova et al. 2014 — Toldova, S., Roytberg, A., Ladygina, A., Vasilyeva, M., Azerkovich, I., Kurzukov, M., ... & Grishina, Y. (2014). RU-EVAL-2014: Evaluating anaphora and coreference resolution for Russian. Computational Linguistics and Intellectual Technologies, 13(20), 681-694.
 10. Vilain et al, 1995 — Vilain, M., Burger, J., Aberdeen, J., Connolly, D., & Hirschman, L. (1995, November). A model-theoretic coreference scoring scheme. In Proceedings of the 6th conference on Message understanding (pp. 45-52). Association for Computational Linguistics.
-



THANK YOU