

**ОСОБЕННОСТИ ОБРАБОТКИ МАЛОРЕСУРСНЫХ ЯЗЫКОВ НА ПРИМЕРЕ СИНТАКСИЧЕСКИ  
АННОТИРОВАННОГО КОРПУСА (Трибанка) UD\_ARMENIAN**

«Сохранение языков народов мира и развитие языкового разнообразия в  
киберпространстве: контекст, политика, практика»  
(Якутск, 1-5 июля 2019 г.)

Яврумян Марат Мнацаканович  
канд. филол. наук, доцент кафедры арабистики  
Ереванского государственного университета

В настоящее время разработано множество моделей и алгоритмов для задач обработки естественного языка, для ряда наиболее используемых языков мира создано и успешно используется множество коммерческих систем, доступны электронные словари, машинные переводчики, системы синтеза и распознавания речи. Но, несмотря на это, существуют задачи, которые не решены до конца ни для одного из мировых языков (автоматизация семантического анализа, анализ тональности текста или внеязыковой информации, содержащейся в тексте и т.д.). Кроме того, степень развития электронных инструментов анализа текста сильно отличается между различными языками. Так, высокое качество работы таких систем для западноевропейских языков или китайского сочетается со слабым развитием или даже их полным отсутствием для многих других языков. В мире сегодня насчитывается более 7 000 живых разговорных языков, и только для небольшого числа из них существуют необходимые электронные ресурсы и программное обеспечение для реализации естественно-языковых и речевых технологий (Хусаинов 2014, Карпов 2015).

Важно отметить, что современные информационные технологии в основном связаны с теми естественными языками, для которых доступны необходимые электронные ресурсы, или же с языками, которые по какой-либо экономической или политической причине стали представлять интерес для мирового сообщества. Бóльшая же часть языков развивающихся стран и малочисленных народов на сегодняшний день в этом отношении изучена недостаточно.

Таким образом, в мире выделяется класс так называемых малоресурсных языков (low-resource languages), для которых не создано средств автоматической обработки текста или распознавания речи, что препятствует их использованию в современных информационных

системах способствуя их вытеснению ведущими мировыми языками. Такие языки в эпоху цифровых технологий, остаются, скажем так, «печатными языками». И так, малоресурсными (термин предложен Krauwer 2003, Berment 2004) считаются языки, для которых развитие информационных технологий является недостаточным.

Важно подчеркнуть, что языки национальных меньшинств и малочисленных этносов — т.н. миноритарные языки, не то же самое, что малоресурсные языки, которые могут быть государственными, национальными или официальными языками, причем иногда с очень большим количеством носителей. С другой стороны, некоторые языки национальных меньшинств можно рассматривать как языки с достаточными ресурсами (например, каталанский). Малоресурсные языки не обязательно являются и вымирающими, хотя обратное утверждение чаще всего верно (Мурадова 2008). И так, в основу определения малоресурсных языков, ставится, таким образом, количественная оценка степени информационного или, скажем так, технологического развития языка. Кроме того, языки, которые становятся сильными в политической, социальной или экономической сфере, могут в дальнейшем стать сильными и в инфокоммуникационной среде, в сфере информационных технологий. В качестве примера можно отметить языки быстро развивающихся стран (малайский, вьетнамский, бенгальский, урду, суахили и т. д., некоторые из которых уже находятся в двадцатке наиболее общеупотребительных языков мира).

Факт слабого развития информационных технологий для малоресурсных языков, может быть объясним целым рядом причин. Во-первых, данная ситуация объясняется научной сложностью стоящих перед исследователями задач. Во-вторых, высокими финансовыми затратами на подготовку необходимых программных инструментов, текстовых корпусов, исследовательских ресурсов. Однако важным также является тот факт, что существующие до определенного момента решения не учитывали все особенности работы с малоресурсными языками.

Количество достаточно хорошо исследованных языков с необходимыми языковыми и речевыми корпусами легко перечислить, назвав число языков, которые учитываются в современных информационных технологиях по обработке естественного языка и речи, таких, как переводчик Google Translate (80 языков в 2014 г., и 104 языка в 2019 г.), словарь Wiktionary и энциклопедия Wikipedia (более сотни языков) или международный

консорциум синтаксически размеченных корпусов Universal Dependencies (146 трибанков на 83 языках мира, по данным 15 мая 2019 г.), о чем и речь пойдет в дальнейшем.

Пример, который я хотел бы привести, показывает, что подход, учитывающий специфику обработки малоресурсных языков, существенно сокращает время сбора нужных данных для создания средств автоматизации обработки языка, сопоставимых по качеству работы с существующими мировыми аналогами.

Проблемы, характерные для обработки малоресурсных языков являются насущными также и для армянского языка, несмотря на то, что общее число говорящих на армянском по всему миру — около 5,9-6,7 млн. человек, язык имеет статус государственного и официального в Республиках Армении и Арцаха. Кроме того, согласно исследованиям Массачусетского технологического института, армянский — один из 50 наиболее влиятельных языков мира. Армянский имеет долгую историю изучения — история армянской лингвистики насчитывает более 1500 лет. Отметим, что различаются два новоармянских литературных языка — «восточный» и «западный», и малоресурсными можно считать оба ветви. В дальнейшем речь пойдет только о восточноармянском языке.

Интересно, что проблема сбора баз данных или текстовых корпусов для армянского стоит не так уж остро, несмотря на значительное языковое разнообразие, например, Национальный корпус восточноармянского языка «АРЕВАК», объем которого составляет более 110 млн морфологически размеченных словоупотреблений. В рамках международного проекта UNL – Universal Network Language был разработан также и модуль обработки восточноармянского. Но парадокс в том, что все эти ресурсы являются закрытыми, они не обеспечивают возможности создания новых программных инструментов для обработки текста и распознавании речи — в конечном счете они мало способствуют информационному развитию армянского языка, и он по-прежнему остается малоресурсным.

Подобная практика характерна не только для армянского. Она стоит остро и для других языков. В этом контексте для работы над базами данных был создан международный консорциум лингвистических данных LDC (<https://www ldc upenn edu>), запустивший проект по созданию текстовых и речевых корпусов для многих языков, в рамках которого открыт коммерческий доступ к обучающим корпусам для распознавания и синтеза речи, машинного перевода и т. д. Европейская ассоциация по языковым ресурсам ELRA (<http://www elra info>) также имеет в своем каталоге базы данных и информационные

ресурсы для десятков языков мира. Был инициирован и международный проект OPUS — открытый параллельный корпус переведенных текстов из интернета.

Особенный интерес представляют международные проекты для создания и лингвистической разметки баз данных, которые могут последовательно применяться ко многим языкам. Отметим проект «Универсальные зависимости» (Universal Dependencies, UD), который был запущен в 2015 г. и который, основываясь на усилиях по унификации сегментации, морфологической и синтаксической разметки текста, ставит целью представить кросс-лингвистически или универсально применимый набор тегов частей речи (POS-tagging) и отношений зависимостей (dependency relations), а также большое количество единообразно размеченных банков синтаксических деревьев (treebanks). В рамках этого проекта в 2018 году (в течение полутора лет после его начала) был запущен банк восточноармянского языка — UD\_Armenian-ArmTDP, по стандартам UD были описаны морфология и синтаксис армянского языка (<https://universaldependencies.org/hy/>). Усилия по созданию банка позволили обеспечить те минимальные условия, которые привели к возможности автоматизировать решение отдельных задач, необходимых для полной обработки армянского. Был создан модуль токенизации или автоматической сегментации текста, модуль морфологического разбора, модуль лемматизации, веб-инструмент для ручной синтаксической разметки текста. Все разработки в рамках этого проекта, и сам трибанк, распространяются согласно лицензии открытого доступа. Т.е. разработки, включая и сам банк, открыты не только для научно-исследовательских целей, но для коммерческого использования (<https://armtreebank.yerevann.com>).

Через неделю после второго релиза трибанка (ноябрь 2018 г.), восточноармянский был включен в пакет программного инструмента StanfordNLP, и еще через три дня в пакет Sрасу.іо, который специализируется в коммерческом секторе обработки естественного языка. Армянский был классифицирован малоресурсным в международном соревновании CoNLL Shared Task 2018, как подходящий для демонстрации возможностей программных решений и нейросетей, разрабатываемых для комплексов таких языков (малоресурсных языков проекте UD в 2018 году было 8). Участие в этом соревновании дало нам возможность на базе нейронной сети COMBO (Rybak, Wroblewska 2018) запустит онлайн ресурс «Парсер армянского языка» (<https://parser.yerevann.com>), который обеспечивает автоматическую обработку (сегментация и морфологический анализ текста, построение синтаксических деревьев зависимостей) на уровне точности в среднем 85%.

Итак, в контексте работы с малоресурсными языками доступность отдельных решений и первичных инструментов их обработки, а также работа в тесном международном сотрудничестве снимают ограничения, которые являлись сдерживающим фактором для информационного и технологического развития класса малоресурсных языков, существенно сокращая разрыв между уровнем разработок для малоресурсных языков и системами для ведущих мировых языков, или, по крайней мере, позволяя учитывать факт существования малоресурсных языков при проектировании и реализации отдельных программных инструментов.

---

Карпов А. А., Верходанова В. О. Речевые технологии для малоресурсных языков мира. *Вопросы языкознания*, 2015. №2, с. 117-135.

Мурадова А. Р. Как исчезают языки и как их возрождают. *Языковое разнообразие в киберпространстве: российский и зарубежный опыт*. М.: МЦБС. 2008. С. 70-75.

Хусаинов А. Ф. Технология автоматизации создания и оценки качества программных средств анализа речи с учетом особенностей малоресурсных языков. Дис. канд. техн. наук. Уфа, 2014.

Berment V. Méthodes pour informatiser des langues et des groupes de langues «peu dotées». Thèse de doctorat, Université Joseph Fourier. Grenoble, 2004.

Krauwer S. The Basic Language Resource Kit (BLARK) as the First Milestone for the Language Resources Roadmap. In *Proc. International Workshop on Speech and Computer SPECOM-2003*. Moscow, Russia, 2003. Pp. 8-15.

Piotr Rybak and Alina Wroblewska. Semi-Supervised Neural System for Tagging, Parsing and Lemmatization. In *Proceedings of the CoNLL 2018 Shared Task: Multilingual Parsing from Raw Text to Universal Dependencies*, pp. 45-54, Brussels, Belgium, October 31-November 1, ACL, 2018.