

АЛГОРИТМ АВТОМАТИЧЕСКОЙ ГЕНЕРАЦИИ СПИСКА ЛЕММ И СЛОВОФОРМ ДЛЯ ПРЕДМЕТНОЙ ОБЛАСТИ ФУНДАМЕНТАЛЬНОГО И ПРИКЛАДНОГО РЕЧЕВЕДЕНИЯ¹

В статье рассматривается проблема обработки недетерминированных слов и составление алгоритма, в ходе которого генерируется совокупность словоформ для слов, отсутствующих в словаре. Описываемый алгоритм рассматривается применительно к русскому языку. Анализируются современные подходы к морфологическому анализу, а также достоинства и недостатки современных инструментов морфологической разметки текстов на русском языке.

Ключевые слова: *предредактирование, лемматизация, морфологический анализ, настройка на предметную область.*

Оськина К. А. Алгоритм автоматичної генерації списку лем і словоформ для предметної галузі фундаментального та прикладного мовленнєзнавства. – Стаття.

У статті розглядається проблема оброблення недетермінованих слів і складання алгоритму, під час якого генерується сукупність словоформ для слів, відсутніх у словнику. Описаний алгоритм розглядається стосовно російської мови. Аналізуються сучасні підходи до морфологічного аналізу, а також переваги й недоліки сучасних інструментів морфологічної розмітки текстів російською мовою.

Ключові слова: *передредагування, лематизація, морфологічний аналіз, налаштування на предметну галузь.*

Oskina K. A. Algorithm of automated lemma and wordform list generation for subject domain of fundamental and applied speech studies. – Article.

This article deals with the problem non-deterministic words processing for Russian. An algorithm of generating a list of lemmas and wordforms for such words is considered. Modern approaches to morphological analysis are investigated. The advantages and disadvantages of modern tools of Russian texts POS-tagging are reviewed as well.

Key words: *automatic pre-editing, lemmatization, morphological analysis, domain adaptation.*

Введение. Существующие решения в области семантического анализа достаточно эффективны при их использовании в хорошо формализованных предметных областях, то есть в случае наличия исчерпывающих словарей. Однако в случае, когда модуль семантического анализа сталкивается с недетерминированной лексикой, например, неологизмами или заимствованиями, качество результатов заметно снижается. Описанный в работе алгоритм лемматизации положен в основу подсистемы предредактирования в перспективном модуле семантического анализа, разрабатываемого на кафедре прикладной и экспериментальной лингвистики Московского государственного лингвистического университета.

Системы машинного перевода (далее – СМП) начали создаваться в 1960-х гг., однако большинство проблем, с которыми сталкивались их разработчики, так и не были решены. К основным проблемам машинного перевода относится нехватка достаточного количества словарей, обработка идиом, грамматическая и семантическая неоднозначность, проблемы определения интерлингвы. Основной трудностью при разработке релевантной системы является возможность адаптации СМП к особенностям предметной области [14, с. 161].

В настоящее время на кафедре прикладной и экспериментальной лингвистики Московского государственного лингвистического университета под руководством д-ра филол. наук, проф. Р.К. Потаповой проводятся исследования, направленные

на разработку алгоритма автоматического определения значений слов с настройкой на предметную область (далее – ПО) фундаментального и прикладного речеvedения. Основными проблемами лексического пласта вышеуказанной ПО является наличие омонимов и полисемов вследствие заимствования терминов из других предметных областей, а также большое количество неологизмов, что приводит к трудностям при обработке тематических текстов методами, основанными на словарях.

В целях формального описания предметной области необходимо сформировать список базовых форм и соответствующих им словоформ. Построение лемматизатора для вышеуказанной предметной области позволяет решить ряд проблем, связанных с обработкой и тэгированием объемных текстовых массивов, в частности, проблемы сортировки и систематизации текстовых массивов, сегментации текстов, общелингвистического поверхностного анализа, или аннотирования, текстов, внутренней разметки (расстановка морфологических, синтаксических и семантических обозначений) [11, с. 95].

Современные подходы к морфологическому анализу. В современных модулях морфологического анализа принято выделять два подхода к организации словарей лексики языка: *лемматизация* и *стемминг*. *Лемматизацией* называют подход, при котором в главном словаре анализатора хранятся леммы – основные формы слов с указанием основы. Ему противопоставляется *стем-*

¹ Проект поддержан Российским научным фондом (РНФ), проект №14-18-01059. Науч. рук. – д-р филол. наук, проф., действительный член Международной академии информатизации Потапова Р.К.

минг – подход без использования словаря основ. В стемминге есть только правила обрабатывания суффиксов и небольшие словари исключений [9, с. 21]. Стемминг используется в тех случаях, когда морфология не важна.

Оба метода имеют свои достоинства и недостатки. Для стеммингового метода характерна высокая скорость анализа за счет упрощения алгоритма и уменьшения объема выдаваемой информации; при отсутствии словаря основ по факту становится доступной морфологическая база неограниченного объема, настраиваемая непосредственно на имеющийся текст, что является практичным при создании информационно-поисковых систем с нефиксированной лексикой. Однако стемминговый метод характеризуется невысокой точностью, невозможностью морфологического синтеза на базе без основ, возможностью порождения одинаковых стемов для различных слов («люб» для «люб-овь» и «люб-ить»), смешением различных понятий (к «люб-ить» будет отнесен глагол «люб-оваться»). Также стемминговый метод не справляется с обработкой чередования гласных (для слова «идти» стемы «ид», «шл», «ше») [4, с. 119]

Лемматизаторы, напротив, характеризуются высокой точностью выдаваемых результатов. Наряду с этим они справляются с супплетивизмом и чередованием. К минусам лемматизаторов относится то, что совокупность словоформ, полученных в результате их работы, занимает больше памяти относительно данных, хранимых при обработке стемминговыми методами. В то же время с учетом современного уровня развития вычислительных мощностей этой разницей можно пренебречь. Помимо этого, лемматизаторы не справляются с такими проблемами, как омонимия и полисемия, однако в пределах единой предметной области данный недостаток не является критичным. Так, из-за распространения в русском языке таких явлений, как супплетивизм и чередования [9, с. 21], наиболее оптимальным для его обработки будет использование лемматизатора.

Предморфологический анализ. Первым шагом для разработки лемматизатора является сбор корпуса по фундаментальному и прикладному речеведению. На этом этапе был сформирован неаннотированный корпус лингвистических текстов общим объемом 144 тыс. слов. В корпус вошли статьи из журналов «Вестник Московского государственного лингвистического университета» [5], журнал «Речевые технологии» [7], сборник «Компьютерная лингвистика и интеллектуальные технологии» [6], а также книга Р.К. Потаповой «Речь: коммуникация, информация, кибернетика» [12]. Статьи были собраны произвольно с 2010 по 2016 гг.

Далее необходимо было отобрать словник для специализированного терминологического слова-

ря. Критерием для включения специальной лексики в собираемый словник являлся факт отсутствия слова в списке лемм и словоформ для русского языка. Был написан сценарий на языке программирования Perl [18], который в автоматическом режиме отсеивал из собранного корпуса термины, уже имеющиеся в вышеуказанном списке (рис. 1). Каждая словоформа анализируемого текста последовательно сравнивалась со словоформой из перечня словоформ русского языка. Совпавшие словоформы исключались из текста, остальные выводились в файл, который обрабатывался специалистом вручную. Так был сформирован базис для словника терминологических единиц в вышеуказанной области, который впоследствии может быть дополнен терминами из других текстов и статей в зависимости от анализируемой предметной области.

Общий список выделенных специализированных терминов составил 739 слов. Список лемм и словоформ русского языка был взят из источника [2].



Рис. 1. Орывок из книги Р.К. Потаповой «Речь: коммуникация, информация, кибернетика» после обработки

Частеречная разметка. На следующем этапе необходимо было определить, к каким частям речи относятся слова из полученного списка словоформ. Перед проведением второго этапа были рассмотрены основные проблемы, связанные с морфологическим анализом, а также были апробированы некоторые инструменты, позволяющие производить частеречную разметку в автоматическом режиме:

1) *phr morphology* – представляет собой морфологический анализатор для русского языка, написанный на скриптовом языке PHP, на данном этапе поддерживает и перечень других языков. Существует возможность анализа неизвестных языков со словарями *ispell* (рис. 2) и *АОТ* (рис. 3). Анализатор позволяет решать задачи лемматизации, получения

