

УДК 81'33 + 811.11-112 + 811.512.37
ББК 81.23(2Рос=Калм)

ОПЫТ КВАНТИТАТИВНОЙ ОБРАБОТКИ ТЕКСТА НА СТАРОКАЛМЫЦКОМ ЯЗЫКЕ: КОЛИЧЕСТВЕННЫЕ ХАРАКТЕРИСТИКИ*

Е. В. Бембеев

С развитием информационных технологий в языкознании широкое распространение приобретают методы математического анализа. В современном монголоведении квантитативный подход совсем недавно стал использоваться при исследовании языковых реалий, поскольку только стали создаваться лингвистически аннотированные корпуса монгольских языков [Бадагаров 2008; Бадмаева и др. 2008; Крылов 2012; Куканова 2011а; 2011б; Ринчинов 2009].

Повторяемость языковых, в том числе лексических, единиц и их воспроизведение в различных текстах является наиболее важным условием в количественном описании языкового материала и применения математических методов в лингвистике для его анализа [Долинский 2004: 284]. Квантитативный метод позволяет количественно описывать поведение различных языковых единиц (букв, фонем, морфем, слов, конструкций и т. п.) в письменном тексте (так же как и в устном): частоту употребления тех или иных единиц, их распределение в текстах разного жанра, сочетаемость с другими единицами, выявление разного рода корреляций (например, корреляция частотности слов и изменения их звуковой формы, так называемые аллегривные формы) и т. п. «Одновременно накапливается обобщенная количественная информация о классах единиц, о языковых конструкциях (напр., данные о средней длине слова или предложения, о частоте употребления к.-л. грамматических форм в тех или иных синтаксических функциях и т. п.). Такая информация углубляет описание единиц языка» [Шайкевич 1990: 231].

Возьмем к примеру проблему категории множественности. Простого описания образования форм множественного числа существительных в калмыцком языке явно недостаточно, требуется более глубокое исследование данной категории, в частности и в типологическом аспекте, например в сопоставлении с материалом русского языка. Количественные характеристики текстового

материала тех или иных единиц поможет понять различия в типологическом плане и более полно и основательно проанализировать эту категорию как в функционально-семантическом, так и в грамматическом аспектах. Однако при этом не стоит забывать, что лингвостатистический подход несколько упрощает языковую реальность и охватывает лишь определенный пласт языка и речи.

Актуальность проблемы изучения количественных характеристик в калмыцком языке обусловлена и тем обстоятельством, что большинство этих характеристик до сих пор неизвестны ученым из-за отсутствия представительных и хотя бы относительно сбалансированных корпусов калмыцкого языка. Именно на таком материале можно будет применить дистрибутивно-статистические методы, позволяющие составлять частотные словари и квантитативные грамматики, описывающие частотность единиц лексикологии, дериватологии, морфологии и синтаксиса. Квантитативный подход позволяет классифицировать сами тексты в соответствии с языковыми стилями и жанрами, в рамках которых эти тексты создавались. Поскольку различия между этими стилями и жанрами «носят преимущественно статистический характер», то таким образом можно основать статистическую стилистику калмыцкого языка, описывающую и классифицирующую тексты на строго объективной базе [Шайкевич 1990: 231]. Такая выборка выводит исследователя текста за рамки одного произведения или творчества одного автора и позволяет отсеять индивидуальные явления от общих, тем самым выделяя универсальное и специфическое для каждого отдельного текста или каждого отдельного автора, а также языковой системы в целом. Конечно, в идеале частотное, контекстологическое и концептуально-текстовое направления изучения текста должны не исключать, а гармонично дополнять друг друга. Квантитативный метод исследования предполагает составление частотных слова-

* Исследование выполнено при финансовой поддержке РГНФ, проект «Национальный корпус калмыцкого языка» № 12-04-12047 (2012–2014).

рей, необходимость использования которых для решения прикладных и исследовательских задач несомненна.

Частотный словарь представляет собой модель особым образом преобразованного текста, модель распределения частоты употребления единиц в тексте. Как отмечает в своей работе В. А. Долинский, словарь подобного рода «...включает в себя упорядоченный список слов или других языковых единиц (словоформы, словосочетания), которые зарегистрированы составителем в обследованном им тексте, фрагменте текста или корпусе текстов и снабжены данными о частоте их употребления в тексте (речи). С его помощью можно попытаться ответить на вопросы: как много слов в языке (тексте), с какой интенсивностью они используются в речи, какие из них предпочтительнее в той или иной сфере коммуникации у того или иного автора и т. д.» [Долинский 2004: 285]. Другими словами, речь идет о привычном типе словаря лексем с частотной характеристикой. Различают частотный словарь и ранговый словарь, под последним понимается разновидность первого, в которой инвентаризуемые единицы расположены в порядке убывания употребительности (или то же самое, но только в порядке возрастания рангов).

В настоящей статье нами предпринята попытка квантитативного анализа «раннего» текста, обработка которого является пилотной в процессе создания Национального корпуса калмыцкого языка с целью выявления проблем в автоматической обработке текстов, написанных на «тодо бичиг», а затем транслитерированных на латиницу.

Эксперимент был проведен на материале фототипического издания текста, который в 1897 г. под названием «Сказание о хождении в Тибетскую страну малодербетовского Бааза-бакши» опубликовал профессор Санкт-Петербургского университета А. М. Позднеев [Сказание... 1897]¹. Данный

¹ Рукопись была приобретена у автора Бааза Менкеджуева профессором А. М. Позднеевым, который позднее опубликовал ее с переводом и комментариями. Оригинал рукописи до сих пор не обнаружен. Издание было посвящено XI международному съезду ориенталистов в Париже. Сочинение состоит из 278 страниц: предисловие — 18 страниц (пагинация римскими цифрами, постраничная); перевод занимает 130 страниц (пагинация арабскими цифрами, общая, постраничная); текст на «тодо бичиг» — 120 страниц (пагинация арабскими цифрами, общая, постраничная. На странице 12 строк, сверху вниз, слева направо).

памятник является единственным образцом из сохранившихся до настоящего времени письменных свидетельств оригинального жанра хождений в калмыцкой литературе. Язык текста «Сказания...» неразрывно связан с личностью автора, временем, местом и условиями, в которых он жил.

Прежде чем приступить к обработке данных, необходимо отметить, что анализу на этом этапе подвергались не лексемы, а словоформы², обладающие реальной частотностью в языке текста. Составители частотных словарей отмечают привычность основной словарной единицы — лексемы, — а также тот факт, что при сведении словоформ в лексемы лингвисты могут использовать разные принципы, что приводит к более высокой доле субъективности в количественных показателях по лексемам по сравнению с количественными данными по словоформам. Между тем, по оценке Л. Леннгрена, «...количественные языковые факты, опирающиеся только на уровень словоформ, являются более объективными и надежными» [Леннгрен 1993: 28–29]. Таким образом, в качестве единицы описания выступает слово «от пробела до пробела» в той грамматической форме, в которой она употреблена. Поскольку работа велась по тексту с неснятой омонимией, то иногда статус словоформ получают не собственно словоформы, а «дизъюнктивные пучки (частично) омонимических словоформ» [Крылов 2012: 88].

Текст «Сказания...» обрабатывался в различных лингвистических программах. В ходе его обработки возникло несколько проблем. Например, знак «:», обозначающий долготу гласного и по традиции используемый в транслитерации текстов на латиницу, пришлось заменить на « », поскольку программы ошибочно распознавали его как дефис, т. е. разделитель (так же, как дефис или пробел).

Текст состоит из более 21 тыс. словоупотреблений, а общий список словоформ по частоте представлен более 5 000 единицами, включая имена собственные. Каждой словоформе приписан ранг, а также указана абсолютная частота по всему тексту в целом. Ниже приведен список наиболее частотных словоформ, которые были употреблены в тексте более 50 раз (см. таблицу 1). Табли-

² В нашем случае термин *словоформа* понимается как «слово (лексема) в некоторой грамматической форме (в частном случае — в единственно имеющейся у слова форме), напр.: „сад“, „садами“, „белый“, „белую“, „пишет“, „вчера“» [Зализняк 1990].

ца организована по принципу убывания общей частоты встречаемости словоформ. Дополнительными графами в этом разделе являются «относительная частица» и «часть речи». В последней приводятся названия частей речи в соответствии с общепринятыми пометами, используемыми в Национальном

корпусе калмыцкого языка. В таблице используется знак «~», маркирующий наличие омонимичной формы. Таблица состоит из 6-ти столбцов: А — ранг, В — словоформа, С — перевод словоформы, D — частота, E — относительная частота в %, F — предполагаемая часть речи.

Таблица 1. Список наиболее частотных словоформ в «Сказание о хождении в Тибетскую страну малодербетовского Бааза-бакии»

А	В	С	D	E	F
1.	ene	этот, он, она, оно, они	482	2,16	PRON
2.	nige	один, раз	288	1,29	NUM
3.	tere	тот, он, она, оно, они	233	1,04	PRON
4.	bide	мы	227	1,02	PRON
5.	ügei	нет, не	212	0,95	PART
6.	geži	что [изъясн. союз], сказав [дее-причастие]	188	0,84	CONJ~CONV
7.	biden	мы	185	0,83	PRON
8.	basa	тоже, также	176	0,79	CONJ
9.	bayinai	является, имеется	170	0,76	V
10.	küün	человек	168	0,75	N
11.	tegēd	поэтому	165	0,74	CONJ
12.	gene	говорят	147	0,66	V
13.	gedeg	говоря	143	0,64	CONV
14.	ulus	люди, народ	139	0,62	N
15.	yuuman	[показатель ремы], вещь	132	0,59	N
16.	qoyor	два	129	0,58	NUM
17.	yeke	большой, очень	123	0,55	ADJ
18.	bolōd	сделав, а, что касается; [показатель темы]	121	0,54	CONV
19.	čigi	же	109	0,49	PART
20.	yabugsan	ушел, ушедший	104	0,47	V~CONV
21.	bayidag	являющийся, имеющийся	98	0,44	PTCPL
22.	yabād	уходя	92	0,41	CONV
23.	düngge	подобно [послелог сравнения]	91	0,41	POST
24.	ödör	день	89	0,40	N
25.	bolon	и [союз]	81	0,36	CONJ
26.	yabuži	ходив	79	0,35	CONV
27.	cagtu	временем	76	0,34	N
28.	qonogson	ночевал, ночующий	76	0,34	V~PTCPL
29.	γazar	земля	76	0,34	N
30.	γurbun	три	75	0,34	NUM
31.	irebe	пришел	74	0,33	V
32.	kürtele	до тех пор	73	0,33	POST
33.	cai	чай	72	0,32	N
34.	kiyid	монастырь	72	0,32	N

35.	žige	точно, правда [частица]	72	0,32	PART
36.	γazartu	на земле	71	0,32	N
37.	gegen	гегян, святой	69	0,31	N
38.	blama	лама	66	0,30	N
39.	bayigsan	был	65	0,29	V
40.	dēre	на [последлог], наверху, сверху	63	0,28	ADV
41.	bi	я	62	0,28	PRON
42.	duunai	километр, [расстояние слышимости звука человека]	62	0,28	N
43.	gēd	сказав	61	0,27	CONV
44.	sayin	Хорошо, хороший	61	0,27	ADJ
45.	žigen	точно, правда [частица]	57	0,26	PART
46.	ireži	пришел	56	0,25	V
47.	yabuqu	ходить	51	0,23	V

Анализ представленной выборки с частотой 50 и выше показывает, что наиболее употребительными словоформами является группа указательных и личных местоимений: *ene* 'этот, эта, это' (482), *tere* 'тот, та, то' (233), *bide* 'мы' (227), *biden* 'мы' (185), *bi* 'я' (62). Среди глагольных форм наиболее употребительными являются *bayinai* 'есть, быть' (170) *gene* 'говорит' (147), *gedeg* 'говоря' (143). Существуют большое количество морфологической омонимии. Так, например, слово *geži* употребляется в тексте 188 раз, она может означать изъяснительный союз 'что' или деепричастие 'сказав'. Большой процент употребления занимают глаголы с семантикой движения, что обуславливается характером памятника, описывающего путешествие в далекую страну.

Например: *yabugsan* 'ушедший' (104), *yabād* 'идя' (92), *yabuži* 'ушел' (79), *irebe* 'пришел' (74), *ireži* 'пришел' (56), *yabuqu* 'уйдет' (51). Существительные занимают свою частотную позицию, начиная с 10 ранга: *küün* 'человек' (168), *ulus* 'народ, люди' (139), *yuitan* '(свои) вещи' (132).

Принадлежность автора к религиозной деятельности, а также цель хождения — поклонение святым и буддийским реликвиям также находят отражение в частоте употребления «буддийской» лексики: *küyid* 'монастырь' (72), *gegen* 'гегян, светлость' (69), *blama* 'лама, учитель' (66).

В приведенной ниже таблице 2 показана частотность частей речи с неснятой омонимией, поскольку снятие морфологической омонимии в старописьменном тексте придется проводить, видимо, вручную.

Таблица 2. Список частотности частей речи тексте памятника «Сказание о хождении в Тибетскую страну малодербетовского Бааза-бакиш»

№	Часть речи	Кол-во словоформ	%
1.	N	9095	42,11818
2.	ADJ	934	4,325276
3.	NOM	18	0,083356
4.	N~ADJ	271	1,254978
5.	ADV	766	3,547282
6.	ADV~POST	143	0,662221
7.	NUM	1195	5,533945
8.	PRON	1942	8,993239
9.	Verb	1749	8,099472
10.	Verb~CONV	1367	6,330462
11.	Verb~PTCPL	293	1,356858

12.	CONV	1663	7,701213
13.	PTCPL	978	4,529036
14.	CONJ	434	2,009818
15.	POST	82	0,379735
16.	PART	664	3,074928
Итого:		21594	100%

Из таблицы видно, что лидирующее положение по частоте употребления занимают имена существительные (собственные и нарицательные), которые встретились в тексте памятника 9 095 раз. Глагол вместе с омонимичными глагольными формами (Verb + Verb~Conv + Verb~PTCPL) занимает второе место по частоте употребления. Случаев морфологической омонимии, как показывает материал, достаточно много (2 074), что вызывает трудности в его анализе.

Итак, в ходе анализа «раннего» текста выявлен ряд проблем, касающихся транслитерации текста «тодо бичиг», орфографии текста, омонимии словоформ, разметки текста, использования диакритических знаков и т. д. Эти проблемы будут учтены впоследствии при обработке массива текстов на «тодо бичиг» для включения их в Национальный корпус калмыцкого языка. Необходимо реализовать следующие шаги для обработки текстов на «тодо бичиг»:

- видоизменить правила транслитерации текстов на «тодо бичиг»;
- создать грамматический словарь старокалмыцкого текста;
- создать словарь омонимичных форм на старокалмыцком языке;
- создать словарь вариантов написания одного и того же слова;
- создать словарь грамем старокалмыцкого языка.

Отдельной задачей стоит создание программы, распознающей старокалмыцкую письменность, а также конвертера тодо бичиг на латиницу/кириллицу, реализация которых действительно необходима для увеличения «ранних» текстов в корпусе калмыцкого языка, поскольку их изучение носит ретроспективный характер и охватывает самый широкий круг вопросов — от текстологии и диалектологии до сравнительно-исторического изучения словоформ, словосочетаний и т. д. Это может привести в свою очередь к реконструкции ойратских и общемонгольских древностей на вербальном уровне. Нередко в ранних текстах фик-

сируются лексемы и целые последовательности лексем, которые не встречаются в современных данных языка.

Литература

- Бадагаров Ж. Б.* О репрезентативности текстов и элементах программного инструментария для корпуса бурятского языка // Современные информационные технологии и письменное наследие: от древних текстов к электронным библиотекам. Е1 Manuscript-08. Материалы Международной научной конференции (Казань, 26–30 августа 2008 г.). Казань, 2008. С. 28–31.
- Бадмаева Л. Д., Бадагаров Ж. Б., Цыдытов Б. З.* Общие проблемы формирования корпуса бурятского языка // Труды Международной конференции «Корпусная лингвистика – 2008». СПб.: Изд-во Фил. фак-та СПбГУ, 2008. С. 24–30.
- Долинский В. А.* Квантитативная лингвистика в исследовании текста // Алфавит: Строение повествовательного текста. Синтагматика. Парадигматика. Смоленск: СПТУ, 2004. С. 283–324.
- Зализняк А. А.* Словоформа // Лингвистический энциклопедический словарь / под ред. В. Н. Ярцевой; Ин-т языкознания АН СССР. М.: Сов. энцикл., 1990. С. 470.
- Крылов С. А.* Структурно-вероятностная модель современного монгольского языка (на базе Генерального корпуса монгольского языка) // Урало-алтайские исследования. 2012. № 1(6). С. 78–105.
- Куканова В. В.* Архитектура метаописания в Национальном корпусе калмыцкого языка // Вестник Калмыцкого института гуманитарных исследований РАН. 2011а. № 1. С. 139–145.
- Куканова В. В.* Общая структура и перспективы использования Национального корпуса калмыцкого языка в свете проблемы репрезентативности // Материалы XL Международной филологической конференции (10–15 марта 2011 г., Санкт-Петербург). Вып. 24: Полевая лингвистика и интегральное моделирование речи / отв. ред. Н. В. Богданова. СПб.: Изд-во Фил. фак-та СПбГУ, 2011б. С. 125–137.
- Леннгрэн Л. (ред.).* Частотный словарь современного русского языка. Uppsala, 1993. 188 с.
- Ляшевская О. Н., Шаров С. А.* Частотный словарь современного русского языка (на материалах Национального корпуса русского языка).

М.: Азбуковник, 2009. [электронный ресурс] // <http://dict.ruslang.ru/freq.php> (дата обращения: 15.04.2012).

Ринчинов О. С. Корпус бурятского языка и прикладные задачи компьютерной лингвистики // Состояние и перспективы развития бурятского языка. Мат-лы форума бурятского языка. Улан-Удэ, 2009. С. 88–89.

Сказание о хождении в тибетскую страну малодербетовского Бааза-бакши / пер. и коммент. А. М. Позднеева. СПб., 1897. 18 + 130 + 120 с.

Шайкевич А. Я. Количественные методы в языкознании // Лингвистический энциклопедический словарь / под ред. В. Н. Ярцевой; Ин-т языкознания АН СССР. М.: Сов. энцикл., 1990. С. 231.

УДК 81'33

ББК 81.23

СЛОВОИЗМЕНТЕЛЬНЫЕ ТИПЫ В КАЛМЫЦКОМ ЯЗЫКЕ В СВЕТЕ АВТОМАТИЧЕСКОЙ ОБРАБОТКИ ТЕКСТОВ (на примере имени существительного)

В. В. Куканова

Как известно, создание корпуса того или иного языка и его развитие является одной из актуальнейших задач современной лингвистики, в частности и калмыцкого языкознания, поскольку решается судьба языка как средства познания и коммуникации. Для того чтобы корпус «заработал», требуется пройти несколько шагов, связанных не только со сбором репрезентативного текстового материала, его филологической выверки. Одной из первых лингвистических задач является создание морфологического анализатора — программы, приводящей словоформу к начальной форме с приписыванием ей той или иной грамматической информации (грамматем), которую несет данная единица в тексте.

Для реализации этого программного продукта необходима разработанная система словоизменительных типов. Если речь идет о флективных языках, то выделение словоизменительных типов не вызывает никаких недоумений со стороны лингвистов. Система склонения и спряжения здесь более разнообразна и отличается нестандартностью выражения тех или иных граммем. Так, например, для русского языка насчитывается около 10 глагольных словоизменительных классов [Русская грамматика 1980: 647–661] и несколько видов аффиксов для выражения одной и той же грамлемы. Если же говорить об агглютинативных языках, каким является калмыцкий язык, то имеются «сложности» выделения словоизменительных типов, так как они здесь более регулярны, единообразны и стандартны [Булыгина, Крылов 1990].

Во-первых, главной особенностью подобных языков является теоретическая возможность присоединения в строгом порядке неограниченного количества слово-

изменительных аффиксов и частиц к основе слова. Во-вторых, определенный тип парадигмы выделяют на основе общей системы выражения грамматических категорий определенными словоизменительными аффиксами и наличия сходных морфонологических процессов, а также частеречной принадлежности, в пределах которой действует тот или иной образец склонения (к примеру, в русском языке существуют субстантивное, адъективное и местоименное склонения)¹.

В калмыцком языке имеет место четкое противопоставление именного и глагольного словоизменения: для каждого из них существуют неомонимичные аффиксы (сразу же оговоримся: речь идет только о формантах, выражающих определенные грамматические категории имени и глагола). Для всех именных частей речи — существительных, местоимений (за исключением некоторых форм с супплетивными основами), числительных — используются те же самые словоизменительные аффиксы для выражения категорий числа², падежа и др. По сути,

¹ Е. С. Кубрякова и П. А. Соболева выделяют пять следующих обязательных признаков морфологической парадигмы: 1 — «наличие константной лексемы, выражающей в парадигме идею тождества слова самому себе во всех его видоизменениях, и переменных формантов»; 2 — «наличие константного набора грамматических значений, облигаторного для каждой из фиксируемых форм парадигмы и повторяемого от формы к форме с обязательным изменением одного из них»; 3 — «фиксированное количество переменных грамматических значений»; 4 — «для выражения каждого из грамматических значений (или набора) в парадигме <...> специальный формант»; 5 — «отношения производности, фиксируемые парадигмой» (например, косвенные падежи относительно исходной формы) [Кубрякова, Соболева 1979: 9].

² Категория числа в халха-монгольском языке, по мнению С. А. Крылова, схожа с категорией уменьши-