

АЛЕКСЕЙ ЕВГЕНЬЕВИЧ ПОЛЯКОВ
НПБ им. К. Д. Ушинского / Москва

Корпус церковнославянских текстов: проблемы орфографии и грамматики¹

Ключевые слова: церковнославянский язык, корпусная лингвистика, орфография, словоизменение, морфология, грамматический словарь

KEYWORDS: Church Slavonic language, corpus linguistics, spelling, inflexion, morphology, grammatical dictionary

1. Корпус

В 2012 году впервые в истории мировой науки был создан и открыт для широкого доступа корпус церковнославянских текстов (<http://ruscorpora.ru/search-orthlib.html>). Этот корпус создан в рамках проекта «Национальный корпус русского языка» и открывает собой раздел исторических корпусов русского языка, которые должны охватить историю его развития от XI до XVIII века. Церковнославянский язык по своим лингвистическим свойствам ближе всего к богослужебному языку XVII–XVIII века, когда в основном была оформлена каноническая форма современных богослужебных текстов.

Церковнославянский язык, несмотря на свою старославянскую языковую основу, занимает важнейшее и естественное место в истории русского языка. Он всегда функционировал параллельно с русским и оказал заметное влияние на формирование русского литературного языка, в котором не только многие слова, но даже некоторые грамматические формы имеют церковнославянское происхождение, например, действительные причастия (*делающих, делавший*) и формы превосходной степени (*сильнейший*).

Церковнославянский язык, являющийся важнейшей частью русской культуры, до сих пор не имеет адекватного научного описания, отвечающего современному уровню. Существующие грамматики и словари носят

¹ Данное исследование выполнено при поддержке РГНФ (проект 12-04-12045 «Электронная справочно-информационная система «Грамматический частотный словарь церковнославянского языка») и Программы фундаментальных исследований Президиума РАН «Корпусная лингвистика» (проект «Развитие корпуса церковнославянских текстов»).

Автор данной статьи является основным разработчиком церковнославянского корпуса. Кроме того, активное участие в создании корпуса принимали Е. Р. Добрушина (ПСТГУ), А. Г. Кравецкий (ИРЯ РАН), А. И. Зобнин (Яндекс), и ряд сотрудников ПСТГУ, ИРЯ РАН и компании «Яндекс».

в основном исторический или нормативный характер и описывают некоторую идеальную картину, которая часто не соответствует фактическому состоянию языка, отраженному в текстах. Без обращения к реальным текстам невозможно выяснить, как функционирует конкретное слово, как оно изменяется по формам, какие варианты написания имеет и т.д.

Адекватное научное описание церковнославянского языка должно носить не прескриптивный (нормативный), а дескриптивный (описательный) характер, опирающийся на реальное употребление. Единственной надежной основой для создания такого описания является **корпус** текстов, снабженных специальной разметкой (грамматической, структурной, метатекстовой). Корпус отличается от простого собрания текстов (библиотеки) именно наличием разметки, которая делает возможным поиск слов и словосочетаний по различным критериям (лемма, грамматические признаки, жанр текста и др.) и решение других задач. Корпус является важнейшим инструментом для исследований, который позволяет получить реальную информацию о лексике, грамматике и словоупотреблении из текстов.

2. Тексты и метатекстовая разметка

Церковнославянский корпус включает около 1250 текстов, которые охватывают все основные типы и жанры церковнославянской литературы (богослужбные, святоотеческие, писание, типикон, церковное право). Корпус имеет объем около 4.6 миллиона словоупотреблений и включает около 150 тыс. различных словоформ, которые группируются примерно в 30 тыс. лексем. Корпус такого объема вполне репрезентативен с точки зрения охвата лексики и различных жанрово-тематических групп текстов. Все тексты подготовлены в едином формате и снабжены метатекстовой и грамматической разметкой.

Основным источником текстов для корпуса явилась «Библиотека святоотеческой литературы» (<http://orthlib.ru>). На данном ресурсе собраны результаты титанической работы по оцифровке и переводу в текстовый формат основных церковнославянских книг, за что создатели корпуса приносят искреннюю благодарность его создателям.

К сожалению, тексты в том виде, как они представлены в библиотеке, не вполне пригодны для корпуса. Во-первых, они представлены в нестандартной кодировке НР, которая удобна для набора на клавиатуре, но неудобна для чтения и обработки. Во-вторых, тексты не имеют лемматизации и грамматической разметки, что делает невозможным лексический поиск. Поэтому все тексты, взятые из библиотеки, были существенно переработаны и дополнены для нужд корпуса.

Метатекстовая разметка – это параметры, которые характеризуют текст в целом, а не отдельное слово. Сюда относятся следующие параметры текста:

- 1) Заголовок текста (иногда включает название книги).
- 2) Количество слов.
- 3) Жанр текста.
- 4) Период создания текста.
- 5) Перевод или оригинал.

Жанрово-тематическая классификация текстов ориентирована, прежде всего, на массового пользователя, а не на узкого специалиста, и строится исходя из принципов практического удобства и понятности. Выделяются следующие жанры текстов (с указанием % слов в корпусе):

- а) библия (17%): ветхий завет, новый завет, служба (богослужебное Евангелие);
- б) служба (64%): акафист, ирмологий, минея, октоих, служебник, требник, триодь, часослов;
- в) типикон (5%);
- г) святоотеческий (10%);
- д) право («Книга Правил святых апостолов» = 1%);
- е) научный («Ифика иерополитика» = 0.5%).

Период создания текста определяется условно, поскольку для многих книг невозможно точно определить дату создания, историю редактирования и дату последней правки. Дата издания позволяет определить только верхнюю границу, поскольку некоторые книги могли неоднократно редактироваться на протяжении XVII–XIX веков. В итоге выделяются следующие периоды:

- а) стандарт (XIX–XX = 86%);
- б) архаика (XVII–XVIII – «Пролог», «Добротолюбие» = 2%);
- в) 20 век (3%);
- г) гибридный (8%, например, «Алфавит Духовный»).

Таким образом, основу корпуса составляют современные богослужебные тексты (60%), однако представлены и остальные жанры и периоды. Отдельно стоит старообрядческий «Пролог», который резко отличается от остального массива архаичным языком и орфографией.

3. Орфография и кодировка

Каноническая церковнославянская орфография, ориентированная на точное типографское представление текста, включает множество избыточных символов, имеющих одинаковое фонетическое значение: $u=i=v$, $\phi=\theta$, $o=\phi=w$, $e=\epsilon$, $ia=\alpha$, $ou=yk$, $\bar{w}=om$, $s=z$, $\check{z}=kc$, $\psi=nc$, $\text{ъ}=\text{'}$ (паерок), ударение (острое=тупое=облеченное).

В церковнославянском письме (в отличие от русского) некоторые пары символов используются для различения лексем и грамматических форм:

- в греческих словах сохраняется этимологически правильное написание букв *и–і–ѵ*, *о–ѡ*, *ѡ–ѡ*, *ѡ–ѡ*, *ѡ–ѡ*, *ѡ–ѡ*, например: *августъ–авраамъ*, *акѡндѣнъ*, *ікѡнна*, *тѡхѡнъ*, *ѡѡміамъ*;
- буквы *и–і* обычно распределены позиционно (*і* – перед гласным), однако используются для различения нескольких корней: *миръ* (спокойствие) vs. *міръ* (вселенная), *віно* vs. *вина*;
- буквы *ѡ*, *ѡ* используются для префиксов *о(ѡ)*, *от* и противопоставляются обычному *о*: *ѡблачати* vs. *облакъ*, *ѡбщій*; *ѡсмотрити* vs. *ѡсмъ*; *ѡчаятися* vs. *ѡтчій*, *ѡтрокъ*; в некоторых словах имеется колебание *ѡ/о*: *ѡбразъ/образъ* (но *ѡбразовати*);
- буквы *о–ѡ* используются для различения форм: единственное vs. множественное число (*милости* vs. *милѡсти*, *домомъ* vs. *домѡмъ*), винительный vs. родительный падеж в адъективном склонении (*новаго* vs. *новѡгѡ*, *моего* vs. *моѡгѡ*), прилагательное vs. наречие (*сильно* vs. *сильнѡ*) и в некоторых других случаях;
- для различения омонимичных форм единственного vs. множественного/ двойственного числа также используются буквы *ѡ* vs. *ѡ* и острое vs. обеленное ударение (камора): *конемъ* vs. *конѡмъ*, *іерее* vs. *іерѡс*, *єлени* vs. *єлѡни*, *раба* vs. *раба*, *рабу* vs. *рабу*, *рабы* vs. *рабы*.

Некоторые пары символов имеют нулевую или минимальную различительную способность:

- придыхание ставится автоматически над начальной гласной слова;
- диграф *ѡѡ* пишется в начале слова, лигатура *ѡѡ* в середине и конце;
- *іа* пишется в начале слова, *ѡ* в середине и конце, за исключением корней *іазык-* (народ) vs. *ѡзык-* (орган);
- *ѡ* (широкое) пишется в начале слова, *ѡ* (узкое) в середине и конце, за исключением различения некоторых флексий единственного vs. множественного/ двойственного числа (см. выше);
- *ѡ* (широкое) пишется в начале слова и корня в сложных словах (*ѡтець*, *ѡраѡтець*), *ѡ* (узкое) в прочих случаях.

В результате тщательного анализа церковнославянской графики для представления корпуса в интернете была выработана более простая орфографическая система, которая сохраняет наиболее существенные языковые различия, но не пытается имитировать точный типографский вид текста. В этой орфографии отсутствуют некоторые символы с малой или нулевой различительной способностью (придыхания, различие *ѡѡ/ѡѡ*, *іа/ѡ*), однако сохраняются символы, связанные с различением лексем или грамматических форм (*ѡ–ѡ*, *и–і–ѵ*, *ѡ–ѡ*, *ѡ–ѡ*). Кроме того, были выработаны правила перевода текста из этой орфографической системы в современный вид для удобства поиска.

Словоформы в корпусе представлены в том виде, в котором они встречаются в тексте, а леммы даются в унифицированном написании, в котором не используются избыточные буквы, а титла раскрыты (например, словоформа *млѣть* относится к лемме *милость*).

Для поиска в корпусе можно использовать три орфографические системы:

- 1) Точная – служит для поиска словоформ, сохраняет максимально точный вид словоформы (*е–є, о–о*, титла, ударения) с учетом вышеуказанных отличий от канонической орфографии.
- 2) Упрощенная – служит для поиска лексем, сохраняет основные лексические оппозиции (*о–w, и–i–v, ѳ–θ, з–s*), но игнорирует различия, не служащие для различения лексем (*е=є, о=о*, титла).
- 3) Модернизированная – служит для поиска лемм и словоформ в современной орфографии, включает только современные буквы (*е=t, и=i=v, ѳ=θ, з=s, о=w*).

Точная и упрощенная орфография ориентирована на специалистов, которые знают все тонкости церковнославянской орфографии и хотят получить наиболее точный результат. Модернизированная орфография рассчитана на широкий круг людей, которые хотят искать в корпусе, но не знают, как точно пишется некоторое слово (*лѣто* или *лето*, *ікѡна* или *икона*). Заметим, что модернизированная орфография просто заменяет буквы, но не переводит слово в современное написание (*езеро* ≠ *озеро*, *дѣлати* ≠ *делать*, *аггль* ≠ *ангел*).

Независимо от того, в каком виде слово введено в запрос, результаты поиска всегда выдаются в точной орфографии.

Основные соответствия между орфографическими системами сведены в таблице.

Символ	Каноническая (типографская)	Точная (словоформы)	Упрощенная (леммы)	Модернизи- рованная
придыхание	(есть)	(нет)	(нет)	(нет)
букво-титла	млѣть, блгѣть	млѣть, блгдѣть	милость, благодать	млѣть, блгдѣть
паерок	безазычный	безъязычный	безъязычный	
титла	мѣи, аггль, блдѣть	мѣи, аггль, блдѣть	мати, ангель, благодать	мѣи, аггль блдѣть
оу- / -ук-	оучити, научити	учити, научити	у	у
іа- / -а-	іати, вѣбѣати	яти, вѣбѣати	я	я
ѣ	сѣль	ѣ	ѣ	е
є- / -є-	езеро, кон+ємъ	є (езеро)	е (езеро)	е
о- / -о-	отець, прастець	о (отець)	о (отець)	о
w во флекс.	раб+wmъ	раб+wmъ	(нет)	о
w в корне	ідwль, іkwна	w	w	о
w в префиксе	wбразъ/образъ	w	w	о
ѡ	ѡдати, ѡяти	ѡдати, ѡяти	ѡтдати, ѡтѣяти	от-
i+согл.	ідwль, мѣрь, вѣна	i	i	и
i+глас.	знаніє	i	i	и
и	мѣрь	и	и	и
v ѡ	мѡро, євсѡгнїи	v	v	и / в
θ	анѣразъ	θ	θ	ф
ž	анѣразъ	ž	ž	кс
ψ	апокалѣψисъ	ψ	ψ	пс
s	сло, smіа	s	s	з

Церковнославянские тексты в корпусе представлены в стандартной кодировке Unicode. Нестандартные кодировки, которые применяются при наборе текстов в типографиях (НП, UCS), очевидно, не могут использоваться в интернете. Нам пришлось решать нетривиальную задачу по перекодировке из НП в Unicode, чтобы сохранить максимум значимых различий, присутствующих в исходной кодировке, однако пришлось пожертвовать некоторыми менее значимыми деталями. Дело в том, что некоторые важные символы (*ia*, *ук*, букво-титла) появились в стандарте Unicode относительно недавно (в версии 5.2) и отсутствуют в большинстве доступных шрифтов. При просмотре в интернете браузер (по крайней мере, Mozilla Firefox) автоматически подгружает нужный шрифт и текст выглядит очень красиво, похоже на печатное представление. Однако, если выделить текст и скопировать его в редактор, некоторые символы будут отображаться как пустые квадраты, если на компьютере установлены старые версии стандартных шрифтов. Чтобы не отталкивать пользователей, которые не хотят устанавливать специальные шрифты, мы пожертвовали некоторыми символами: *ou/ук* заменили на обычное *у*, *ia/а* заменили на обычное *я*. Мы считаем, что лучше немного упростить текст, но оставить его читаемым, поскольку буквы *у* и *я* весьма частотны и их потеря существенно затруднит понимание текста (в отличие от потери редких букв – *ѿ*, *ѡ*, *ѣ*, *ѥ*, *Ѧ*). В будущем, когда стандартные шрифты будут включать полный набор славянских символов, можно будет восстановить замененные буквы и тем самым приблизить вид текста в корпусе к канонической орфографии.

4. Грамматическая разметка.

Корпус отличается от простого собрания текстов наличием лингвистической разметки (грамматической, синтаксической, семантической и т.д.) и возможностью поиска по этой разметке. Для языков с богатой морфологией прежде всего необходима грамматическая разметка, которая обеспечивает возможность поиска слов по лемме (словарной форме) и грамматическим признакам. Поиск по точной словоформе (даже с усечением или шаблонами) абсолютно недостаточен для церковнославянского языка, в котором некоторые классы лексем имеют по несколько десятков словоформ (например, глаголы, включая формы причастий).

Грамматическая разметка для корпуса включает следующие задачи:

- 1) лемматизация – приведение словоформы к лемме (словарной форме) и определение ее грамматических признаков (часть речи, род, вид, переходность);
- 2) грамматический анализ – определение грамматических признаков словоформы (падеж, число, время, лицо, наклонение).

Эти задачи могут решаться одновременно, но с разной степенью полноты и точности. Пользователям прежде всего нужен поиск по лемме и части речи, в меньшей степени – по другим грамматическим признакам. Кроме того, в церковнославянском очень распространена грамматическая омонимия между словоформами одной лексемы, поэтому точно определить их грамматические признаки часто невозможно.

Существующие грамматики и словари церковнославянского языка не дают полной картины словоизменения. Грамматики приводят парадигмы для наиболее частотных слов, а также отдельные примеры вариативных форм. Словари обычно включают наиболее частотные или важные слова, а грамматическая информация дается фрагментарно или не дается вообще. В результате нередко невозможно выяснить, какие реальные формы имеет данное слово, а спорные вопросы остаются без ответа (примеры см. в п. 5). В таких случаях единственным достоверным источником является корпус.

Грамматическая модель словоизменения церковнославянского языка не задается априорно на основе существующих грамматик и словарей, а выводится эмпирически на основе анализа данных корпуса. Модель словоизменения включает в себя два основных компонента:

- 1) грамматический словарь,
- 2) таблица словоизменительных типов (парадигм).

Грамматический словарь представляет собой список лексем с приписанной им информацией о словоизменении. Каждая лексема в словаре содержит, как минимум, следующие параметры:

- лемма (словарная форма) и ее варианты (если есть);
- постоянные признаки лексемы (часть речи, одушевленность, переходность);
- код парадигмы и особенности словоизменения (нерегулярные словоформы);
- краткое толкование для устаревших и малопонятных слов (по необходимости).

Словоизменительный тип (парадигма) представляет собой список грамматических значений и соответствующих им грамматических форм, общий для некоторого множества лексем.

Парадигмы также не задаются априорно на основе существующих описаний, а выводятся из корпуса на основе анализа множества словоформ, имеющих однотипное соотношение между грамматическими формами. Таким образом, номенклатура парадигм получается значительно более детальной и может существенно отличаться от традиционных грамматик. Например, традиционное первое склонение (*рабъ*) распадается на 14 подтипов в зависимости от конечного согласного (парный твердый–мягкий, велярный, шипящий, йот), наличия беглого гласного и других особенностей.

Вот небольшой фрагмент таблицы парадигм в формальной записи.

Парадигма	N1t	N1t*	N1j	N1k	N1x	N1k*
Пример	рабъ	осель, сонъ	конъ, царъ	отрокъ	духъ	свитокъ
Основа	раб+ъ	осе*л+ъ, со*н+ъ	кон+ъ, цар+ъ	отро(к ц ч)+ъ	ду(х с ш)+ъ	свит(к ок ц ч)+ъ
sg,nom	ъ	2ъ	ъ	ъ	ъ	2ъ
sg,acc	=nom/gen	=nom/gen	=nom/gen	=nom/gen	=nom/gen	=nom/gen
sg,gen	a	a	я	a	a	a
sg,dat	y	y	ю	y	y	y
sg,loc	ѣ	ѣ	и	2ѣ	2ѣ	3ѣ
sg,ins	омъ	омъ	емъ	омъ	омъ	омъ
sg,voc	e	e	ю	3e	3e	4e
pl,nom/voc	и	и	и/ie	2ы	2и	3ы
pl,acc	ы/=gen	ы/=gen	и/=gen	и/=gen	и/=gen	и/=gen
pl,gen	wвъ/ъ^	wвъ/ъ^	ей	wвъ	wвъ	wвъ
pl,dat	wмъ	wмъ	емъ	wмъ	wмъ	wмъ
pl,loc	ѣхъ	ѣхъ	ехъ	2ѣхъ	2ѣхъ	3ѣхъ
pl,ins	ы	ы	и/ьми	и	и	и
du,nom/acc	a^	a^	я^	a^	a^	a^
du,gen/loc	y^	y^	ю^	y^	y^	y^
du,dат/ins	ома	ома	ема	ома	ома	ома

В этой таблице в первой строке указаны коды парадигм, в первом столбце – грамматические формы в виде набора признаков. Во второй строке даются примеры лемм в обычной записи, в третьей – в формате грамматического словаря. Чередования записываются как формулы вида (x|y|z), например, *отро(к|ц|ч)* означает, что основа имеет три варианта – *отрок*, *отроц*, *отроч*. Номер варианта используется при записи флексий, причем первый вариант считается основным. Например, флексия «у» требует первого варианта основы (*отрок+у*), флексия «2ѣ» имеет форму «ѣ» и требует второго варианта (*отроц+ѣ*), флексия «3е» требует третьего варианта (*отроч+е*).

Грамматический словарь и модель словоизменения создаются эмпирически и итеративно. Сначала из корпуса генерируется список словоформ и делается его первичная проверка и чистка (исправляются явные ошибки). Затем для частотных слов делается ручная лемматизация, определяются типичные шаблоны и строится первичная модель словоизменения. Далее на основе шаблонов разобранных словоформ анализируются другие словоформы, затем автоматические разборы проверяются и правятся вручную, снова

уточняется грамматическая модель, и так далее. На последнем этапе разбираются вариантные и уникальные словоформы и принимается решение о том, что с ними делать (исправить, включить в словарь, считать исключением, игнорировать).

В настоящее время создана пилотная версия грамматического словаря, которая используется для поиска в корпусе. Было проанализировано около 150 тыс. словоформ, которые в итоге были сведены примерно в 30 тыс. лемм. В результате ручной, а затем автоматической лемматизации удалось приписать грамматические разборы большинству словоформ. Часть словоформ была квалифицирована как ошибки (опечатки), а для некоторых редких форм лемму определить не удалось или она была определена гипотетически.

5. Вариативность

В церковнославянских текстах имеется множество орфографических и словоизменительных вариантов, обусловленных тем, что тексты создавались в разное время и в разной языковой среде. Вот некоторые примеры.

1) В грамматиках дается список слов и корней, которые обычно пишутся под титлом: *агѣль*, *апѣль*, *бѣъ*, *ѣдѣ*, *млѣть*, *мѣи*, *стѣй*, *члѣкъ*. Возникает вопрос: всегда ли эти корни пишутся именно так (под титлом), а если нет, то как еще они могут писаться? Ответ на этот вопрос может дать только корпус. В результате анализа разных написаний в корпусе оказывается, что например, корень *апостол-* может писаться тремя способами: *апостол-* (полностью раскрыто), *апѣл-* (полностью сокращенно), *апѣтол-* (частично сокращенно); основа прилагательного *ангельскій* пишется тремя способами: *агѣльск-*, *агѣлск-*, *агѣльск-*. Без корпуса выявление всех реально встречающихся вариантов было бы просто невозможно.

2) В грамматиках написано, что для различения омонимичных форм единственного и множественного/двойственного числа может использоваться замена букв (*о*→*ѡ*, *е*→*ѣ*) или замена острого ударения на облученное (ка-мору). Таким образом, возникает конкуренция орфографических правил и непонятно, какое из них нужно применять в конкретном случае. Например, как будет множ. число от слов *милость*, *высота*: *мѣлѡсти* (*о*→*ѡ*) или *мѣлѡсти* (камора), *высѡты* (*о*→*ѡ*) или *высоты* (камора)? Ответ на этот вопрос может дать только корпус, который дает следующую статистику: *высѡты* (17 раз), *высоты* (9 раз), *высѡты* (1 раз), *мѣлѡсти* (93 раз), *мѣлѡсти* (2 раза). Из анализа других аналогичных примеров мы можем сделать вывод, что при конкуренции правил замена *о*→*ѡ* более предпочтительна, чем замена ударения.

3) В грамматиках написано, что слова с суффиксом *-тель* типа *дѣлатель* могут иметь особые формы именит. множ. на *-е* (*дѣлателие*, как *агаряне*) и на *-іе* (*дѣлателие*, как *царіе*). Кроме того, они могут иметь стандартные

формы на *-и* (*дѣлатели*). Естественно, возникает вопрос о том, какие из этих форм реально встречаются и с какой частотой. Решить подобный вопрос возможно только при помощи корпуса, который дает следующую статистику: *дѣлатели* – 36 раз, *дѣлателіе* – 18 раз, *дѣлателе* – 13 раз. Таким образом, для данного слова чаще всего употребляется стандартная форма, за ней идет форма на *-іе*, а затем на *-е*. Для получения достоверных выводов нужно проанализировать остальные слова с суффиксом *-тель*, а также другие слова с аналогичными особенностями (с суффиксом *-арь* и т.д.).

4) Церковнославянский язык является смешанным по своему грамматическому строю. Многие грамматические формы совпадают с русскими, а несовпадающие, происходящие от старославянских, нередко вытесняются эквивалентными русскими формами. Например, наряду со старославянской формой *на земли* встречается русская форма *на землю*; предложный падеж множественного числа от слов первого склонения имеет вариативные формы *селѣхъ/селахъ*, *жилицѣхъ/жилицихъ*, но только *моряхъ*, *мужахъ* (при отсутствующих **морихъ*, **мужихъ*). Вопрос о конкуренции старославянских и русских форм изучен совершенно недостаточно, а для получения достоверных результатов нужен корпус.

Church Slavonic corpus: spelling and grammar problems

Church Slavonic corpus, opened in 2012, can dramatically improve the accuracy and objectivity of Church Slavonic language studies. The corpus differs from a collection of texts by special markup (grammatical, structural, metatextual) and search facilities. Existing grammars and dictionaries are of historical or regulatory nature and often do not match the facts reflected in real texts. This paper discusses the problem of spelling representation and grammatical tagging of texts in the corpus and its usage for studying grammatical variation.