



Применение методов машинного перевода для анализа древнерусских музыкальных рукописей



Даньшина М.В.


Научный руководитель – Филиппович А.Ю.

Древние музыкальные рукописи

Собрание Д.В.Разумовского и В.Ф. Одоевского


Сборники песнопений:

- на крюковых нотах – 83 рукописи
- на линейных нотах – 43 рукописи
- двузнаменные – 3 рукописи



- Синодальное собрание славянских рукописей - 1172 фолианта.
- Рукописей Соловецкого монастыря - 202 рукописи
- Общество любителей древней письменности - 624 славяно-русских и нескольких греческих рукописей

Сложность перевода



Знамя – графическое изображение ноты

Особенности знамен

- Перевод, представленный в азбуках, *неоднозначен*
- Одно знамя может представляться несколькими нотами
- Не все знамена представлены в азбуках



Попевка – последовательность знамен с особенные значением (переводом).

Особенности попевок

- Большое количество попевок (>2 000)
- Попевки объединялись в сборники
- Зависимость перевода от текста

Сборник попевок
Соловецкого собрания
содержит 213 страниц
(~2000 попевок)

$P = \{ \{ Z \}, N, G \}$, где $Z = \{ \langle z, s \rangle \}$,
где P-попевка, N-название, G-глас,
z-знамя, s-слог.

$S = \{ \langle z, nota, s \rangle \}$,
где S – словарь, nota-
перевод знамени.

Исследуемые рукописи

Круг древнего
знаменного пения 1884г.




1367 страниц (6 томов)



Ирмологий 17 в.



68 страниц



Сборник попевок
Соловецкого собрания



213 страниц



Использование методов машинного перевода

- 1) Прямой (пословный) перевод
- 2) Использование правил
- 3) Статистический перевод

Музыкальный редактор

Вывод песнопения в крюковой нотации

Грант РГНФ
№11-04-12025в

Новости Песнопения Исследования

Музыкальный проигрыватель семиографических песнопений - веб-приложение крюковой нотации в линейную (квадратную), а также проигрывания получившихся

semio2.xml by mdanshina semio2.xml by mdanshina

Ве чер ня я на ша мо лит вы, при
и ми свя тый Го спо ди. и по даждь
на о ста кле ни е грэ ховъ. з ко
ты е днь е си зк лей въ ми рэ во
саре се ни е.

CLAIM © Компьютерная Сем


Пример азбуки в xml-формате

```
<ROWDATA>  
<ROW cod="200" note="e_1" length="04" p="0.7"/>  
<ROW cod="144" note="f_1" length="04" p="0.9"/>  
<ROW cod="304" note="g_1" length="04" p="0.9"/>  
<ROW cod="269" note="f_1" length="04" p="0.4"/>  
<ROW cod="177" note="e_1" length="04" p="0.4"/>  
<ROW cod="256" note="f_1" length="04" p="0.5"/>
```

Пример песнопений в xml-формате

```
<ROWDATA>  
<ROW Znam="a" Slog="ко" Stil="обычный" VPom="м" DPom=""/>  
<ROW Znam="Ap" Slog="кэч" Stil="обычный Italic" VPom="в" DPom=""/>  
<ROW Znam="a" Slog="но" Stil="Bold" VPom="п" DPom=""/>  
<ROW Znam="a" Slog="му" Stil="Bold" VPom="п" DPom=""/>  
<ROW Znam="a" Slog="т" Stil="Bold" VPom="п" DPom=""/>  
<ROW Znam="a" Slog="от" Stil="Bold" VPom="п" DPom=""/>  
<ROW Znam="a" Slog="шу" Stil="Bold" VPom="п" DPom=""/>  
<ROW Znam="a" Slog="ся" Stil="Italic" VPom="п" DPom=""/>
```

Статистический машинный перевод



Модель языка

$$P(w_3|w_1, w_2) = \frac{C(w_1, w_2, w_3) + 1}{C(w_1, w_2) + V}$$

Модель перевода

$$P(n|z) = \frac{C(n, z)}{C(z)}, \quad \text{где } C(n, z) \text{ – количество раз, когда последовательность знамен } z \text{ переводится нотами } n$$

Алгоритм декодирования


$$\arg \max_z p(z|n) = \arg \max_z p(z) \cdot p(n|z),$$

где z – триграмма знамен, n – перевод триграммы (ноты), $p(z|n)$ — условная вероятность того, что переводу n соответствовал исходный фрагмент z

$$P(w_1, w_2, \dots, w_m) \cong \prod_{i=1}^m P(w_i | w_{i-n+1}, w_{i-n+2} \dots w_{i-1}), \quad n > 1$$

$$P(w_i | w_{i-1}, w_{i-2}) = \frac{C(w_{i-2}, w_{i-1}, w_i)}{C(w_{i-2}, w_{i-1})}$$


Пример модели языка

N-грамма	Вероятность со сглаживанием	Вероятность без сглаживания	N
	0,01139	0,666667	3
	0,015909	0,857143	2
	0,00431	0,032258	3
	0,056338	0,22963	2
	0,004348	0,037037	3
	0,025271	0,04	2
	0,004228	0,025	3
	0,049878	0,102828	2

Пример модели перевода

Триграмма			Перевод			Вероятность
└	┐	└┐				0,017327
└	┐	└┐				0,318182
└	┐	└┐				0,014851
┐	└	┐└				0,272727
┐	└	┐└				0,073529
└┐	┐└	└┐└				0,3125
└	┐	└┐				0,153846
┐	└	┐└				0,111111
└┐	┐└	┐└┐				0,333333
└	└┐	└┐└				0,2

Ввод песнопений в БД в программе IPSM



С помощью веб-приложения

- Для ввода нот предусмотрены специальные подсказки
- Текущая страница для ввода отображается на экране
- Сохранение дополнительной информации о песнопении (название, страница)

Загрузка XML-файла

- Добавление песнопений, набранных в MS Word
- Специальный формат XML-файла

ROW	
Content: EMPTY	
Id	CDATA
Znam	CDATA
Slog	CDATA
Stil	CDATA
VPom	CDATA
DPom	CDATA

Кодирование знамен

	2112300
	2113100
	2113200
	2113300

- Выделено 202 знамени
- Знамена разделены на 6 групп (максимум 7 подгрупп)
- От 10 до 66 знамен в группе

В результате БД содержит:

- 29376 записей из «Круга...»
- 234 записи приложения к «Круга..»
- 10897 записей двоезнаменника
- 16914 записей сборника попевок

Спасибо за внимание!