

Применение теории нечетких множеств к задаче генеалогической классификации текстов списков средневекового произведения (на примере двух древнерусских письменных памятников)

**Семинар по социофизике
имени Д.С. Чернавского,
Институт проблем управления РАН
Москва, 22.10.2019**

Актуальность темы исследования

- Совершенствование методов исследования
- Привлечение математических методов
- Адаптация теории нечетких множеств к историко-текстологическим исследованиям
- Универсальный и адекватный инструмент

Предмет и цель исследования

- Разработка новой методологии и метода количественной формализованной классификации средневековых текстов с большой рукописной традицией
- Проведение классификации двух средневековых произведений

- Закон Судный людем (57 списков)
- Предсловіе покаянию (21 список)

План доклада

- Элементы текстологии
- Применение мат. Методов в текстологии
- Модель нечеткой классификации
- Элементы теории нечетких множеств

- Алгоритм нечеткой классификации
- Результаты классификации - стеммы
- Проблемы и задачи

- Реконструкция архетипа
- Тексты исторических источников имеют свою историю
- Деление на текстологически близкие группы

- Реконструкция архетипа
- Тексты исторических источников имеют свою историю
- Деление на текстологически близкие группы

- Виды - незначительные, количественные различия
- Изводы – языковая специфика
- Редакции – целенаправленная переработка текста

- Прочтения
- Запоминания
- Внутреннего диктанта
- Письма
- Переосмысления
- Стилистические изменения
- Идейные изменения
- Глоссы и интерполяции
- Работа писца по нескольким оригиналам - правка

Традиционный анализ. Примеры

- бо господа та -> богатства
- всоудъ да възмоутъ -> всегда возмоутъ
- сеи соудъ-> съсоудъ
- иже коупетроу-> иже кусестру / иже петру южику
- О полоне-> о полннн

- Сравнительный анализ текстов списков
- Общие ошибки – результат переписи текста с копии, уже содержащей ошибки
- Группировка по наличию общих ошибок
- Построение генеалогического древа

- Каждый переписчик пользуется одним источником (протографом)
- Одинаковые ошибки писцы делали независимо друг от друга
- “Раздвоенность” стеммы (Ж. Бедье)

Формализация как вспомогательное средство работы текстолога

- Верификация работы текстолога
- Возможность работы с большим количеством текстов списков
- Возможность косвенного датирования неизвестных списков по известным

Формализованная классификация текстов списков

- Метод групп (Д. Фроже, 60-е гг. XX в.; Л.И.Бородкин и соавторы, 70-е гг. XX в.)
- (Colwell, Tunc, 1963), А. Деес, Э. Ваттель
- Матрицы расстояний (Д. Фроже)
- Матрицы близости (Л.И.Бородкин)
- Агрегированные модели (Л.И. Бородкин)

Направления


- Кластерные методы – группировка, внутри которых объекты тесно связаны друг с другом
- Кладистические – принцип парсиномии: в процессе эволюции переход из одного состояния в другое должен произойти за минимальное число шагов

Матрица близости

- Чем “ближе” генеалогически пара списков друг другу, тем меньше различий содержат их тексты
- Сличение списков: Число совпадающих слов
- Максимизация суммарного веса ребер графа связи между списками
- **Проблема:** Матрица симметрична!

- У каждого списка только один протограф
- В каждом списке - все ошибки протографа
- Нет одинаковых ошибок в списках, у которых независимые протографы
- **Проблема:** Жесткие требования к модели


Генеалогическая классификация



Модель нечеткой классификации

- Средневековый текст разнороден по составу
- Трудно указать основной список
- Можно установить предшествование одного другому лишь с определенным уровнем достоверности

Постановка задачи: Идея



Lotfi Askar Zadeh

род. 04.02.1921 г., Новханы,
Азербайджанская ССР

- Fuzzy Sets. Information and Control. N 8. 1965; ...
- Понятие лингвистической переменной и его применение к принятию приближенных решений. М., 1976.


Теория нечетких множеств

- Принадлежность элементов множеству НЕ является однозначной
- Нет жестких границ между множествами
- Учет специфики задач классификации и типологии в гуманитарных науках

Нечеткие множества

- Нечеткое множество \tilde{A} это множество пар

$$\tilde{A} = \{ \langle \mu_A(x) / x \rangle \}, \text{ где } x \in X,$$



Функция
принадлежности
множества \tilde{A} :

$$\mu_A(x) : X \rightarrow [0, 1]$$

Нечеткое отношение

Определение. *Нечетким отношением на множестве X называется и через $\tilde{\eta}(X, V)$ обозначается пара множеств, в котором V является нечетким подмножеством на произведении $X \times X$: $V = \{\mu_V \langle x, y \rangle / x, y \in X\}$, где функция принадлежности $\mu_V \langle \cdot, \cdot \rangle$ ставит в соответствие любой паре элементов базового множества некоторое число из отрезка от 0 до 1: $\mu_V \langle \cdot, \cdot \rangle \in [0, 1]$*

Нечеткие отношения: свойства

- Транзитивность
- Рефлексивность и антирефлексивность
- Симметричность и антисимметричность
- Связанность

Нечеткие отношения: свойства

- Эквивалентности:

транзитивно, рефлексивно, симметрично;

- Порядка (совершенного строгого):

транзитивно, антирефлексивно,
антисимметрично и связано

Нечеткие отношения: свойства

Определение 1. Отношение $\tilde{\eta} = (X, V)$ называется нечетко-рефлексивным, если $\mu_V \langle x, x \rangle \geq \delta$ для любого $x \in X$.

Определение 2. Отношение $\tilde{\eta} = (X, V)$ называется нечетко-антирефлексивным, если $\overline{\mu_V \langle x, x \rangle} \geq \delta$ для любого $x \in X$.

Определение 3. Отношение $\tilde{\eta} = (X, V)$ называется нечетко-симметричным, если $(\mu_V \langle x, y \rangle \rightarrow \mu_V \langle y, x \rangle) \geq \delta$ для любых $x, y \in X$, $x \neq y$.

А.Н. Мелихов, Л.С. Бернштейн, С.Я. Коровин.

Ситуационные советующие системы с нечеткой логикой. М., 1990. 272 с.

Нечеткие отношения: свойства

Определение 4. Отношение $\tilde{\eta} = (X, V)$ называется нечетко-антисимметричным, если $\overline{\mu_V \langle x, y \rangle \& \mu_V \langle y, x \rangle} \geq \delta$ для любых $x, y \in X$, $x \neq y$.

Определение 5. Отношение $\tilde{\eta} = (X, V)$ называется нечетко-транзитивным, если $(\bigcup_{y \in X} (\mu_V \langle x, y \rangle \& \mu_V \langle y, z \rangle) \rightarrow \mu_V \langle x, z \rangle) \geq \delta$ для любых $x, y, z \in X$, $x \neq y, z \neq y$.

Определение 6. Отношение $\tilde{\eta} = (X, V)$ называется нечетко-связанным, если $(\mu_V \langle x, y \rangle \cup \mu_V \langle y, x \rangle) \geq \delta$ для любых $x, y \in X$, $x \neq y$.

А.Н. Мелихов, Л.С. Бернштейн, С.Я. Коровин.

Ситуационные советующие системы с нечеткой логикой. М., 1990. 272 с.

Модель нечеткой классификации: Предположения

- Анализируем только тексты
- Есть текстолог, выделяющий нормальные чтения и уклонения от них (ошибки) в зависимости от времени (и места) создания списка – ранжирование в хронологическом порядке
- Чем больше ошибок одного списка есть в другом, тем достовернее, что первый список предшествует второму
- Чем меньше общих ошибок, тем более “независимы” списки друг от друга

Пример построения отношения предшествования

№ места	Список x	Список y	Общие ошибки списков x и y $S(x,y)$	Ошибки списка x $S(x)$	Ошибки списка y $S(y)$
1	норма	норма	0	0	0
2	норма	ошибка	0	0	1
3	ошибка	ошибка	1	1	2
4	ошибка	ошибка'	1	2	3
5	ошибка	норма	1	3	3
6	норма	ошибка	1	3	4

Нормировка $V(x,y)=S(x,y)/S(x)=1/3$

$$V(y,x)=S(x,y)/S(y)=1/4$$

- 1. Типологизация различий**
- 2. Качественная шкала степеней значимости типов различий**
- 3. Матрица попарных сравнений элементов типологического ряда**
- 4. Определение весовых коэффициентов**

Типологический ряд различий

1. лексические замены
2. пропуски/ вставки глав
3. пропуск/ вставка предложений или их части
4. пропуск/ вставка словосочетаний
5. пропуск/ вставка слов
6. пропуск/ вставка частицы «не»
7. смысловые ошибки
8. пропуск/ изменение названия главы
9. перестановка слов/ нескольких слов
10. исправления

Типологический ряд различий

- 11. Орфография**
- 12. описки, включая повторы**
- 13. Русизмы**
- 14. Архаика**

Качественная шкала степеней значимости типов различий (фрагмент)

Интенсивность значимости	Качественные оценки	Объяснения
0	Тип i несравним с типом j	Нет смысла сравнивать типы
1	Тип i одинаков по значимости с типом j	Типы равны по значимости
3	Тип i слабее по сравнению с типом j	Существуют показания о предпочтении одного типа другому, но показания неубедительные
5	Тип i существенно или сильно	Существует хорошее доказательство и логические критерии, которые

Матрица попарных сравнений элементов типологического ряда

тип- пов	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	XIII	XIV
I	1 α	1 α	3 α	4 α	5 α	3 α	2 α	4 α	8 α	8 α	7 α	9 α	8 α	5 α
II	1 α	1 α	3 α	4 α	5 α	5 α	3 α	6 α	8 α	8 α	8 α	9 α	8 α	5 α
III	1/3 α	1/3 α	1 α	7 α	8 α	8 α	2 α	2 α	7 α	8 α	8 α	9 α	8 α	5 α
IV	1/4 α	1/4 α	1/7 α	1 α	3 α	1/7 α	6 α	7 α	3 α	8 α	8 α	8 α	1/5 α	1/5 α
V	1/5 α	1/5 α	1/8 α	1/3 α	1 α	1/8 α	1/5 α	1/7 α	1 α	5 α	3 α	7 α	1/7 α	1/7 α
VI	1/3 α	1/5 α	1/8 α	7 α	8 α	1 α	1/7 α	0 α	1 α	3 α	0 α	3 α	1/8 α	1/8 α
VII	1/2 α	1/3 α	1/2 α	1/6 α	5 α	7 α	1 α	1/8 α	1/3 α	7 α	8 α	9 α	8 α	1/8 α


Вычисление весовых коэффициентов

$w(\cdot)$	I	II	III	IV	V	VI	VII
Ненормализованные	0,1552	0,1705	0,1433	0,0819	0,0147	0,0443	0,0679
Нормализованные	0,91	1	0,84	0,48	0,086	0,26	0,398
$w(\cdot)$	VIII	IX	X	XI	XII	XIII	XIV
Ненормализованные	0,116	0,0228	0,0072	0,0068	0,0065	0,0689	0,0941
Нормализованные	0,68	0,134	0,042	0,04	0,038	0,404	0,552

Алгоритм нечеткой классификации текстов списков. Подготовительный этап

- Ввод текстов
- Выделение узлов разночтений
- Хронологическое ранжирование отдельных чтений

Алгоритм нечеткой классификации текстов списков. Подготовительный этап



Алгоритм нечеткой классификации текстов списков. Подготовительный этап


	A	B	C	D	E	F	G	H	I	J
1					Нв	Ч	ГП	З	Пчт	РМ
2	1	1		законъ *суднын*людемъ						
3	2	2		правило *царя*константина						
4	2	1975		[]						
5	3	3		законъ-константина						
6	3	1976		[[[]]]						
7	3	5064		константина-законъ						
8	4	4		соуднын						
9	4	1977		суднын						
10	4	4599		соудны						
11	4	6019		суд?нын						
12	5	5		[]						
13	5	3782		всем						
14	6	6		правил?						
15	6	1978		[]						
16	7	7		ц(а)ря						
17	7	1979		[]						

Алгоритм нечеткой классификации текстов списков. Подготовительный этап

	A	B	C	D	E	F	G	H	I
1					Нв	Ч	ГП	З	Пчт
2	1	1	0	законъ *суднын*людемъ	0	0	0	0	0
3	2	2	8	правило *царя*константина	1	1	1	1	1
4	2	1975	8	[]	0	0	0	0	0
5	3	3	9	законъ-константина	1	1	1	1	1
6	3	1976	4	[[[]]]	0	0	0	0	0
7	3	5064	9	константина-законъ	2	2	2	2	2
8	4	4	11	соуднын	1	0	0	0	0
9	4	1977	11	суднын	0	1	1	1	1
10	4	4599	11	соудны	1	0	0	0	0
11	4	6019	11	суд?нын	0	1	1	1	1
12	5	5	5	[]	0	0	0	0	0
13	5	3782	5	всем	1	1	1	1	1
14	6	6	5	правила?	1	1	1	1	1
15	6	1978	5	[]	0	0	0	0	0
16	7	7	5	ц(а)ря	1	1	1	1	1
17	7	1979	5	[]	0	0	0	0	0
18	7	5065	5	и(е)с(а)ря	1	1	1	1	1


Выделение текстологически близких списков

- Задание уровня достоверности.
- Разбиение списков на непересекающиеся эквивалентные классы




Хронологическое ранжирование текстов списков

- Выделение связанных подмножеств на множестве эталонов
- Линейной упорядочивание связного подмножества




Хронологическое ранжирование текстов списков

- Покрытие множества эталонов



Стемма «Предсловия Покаянию» (порог 65%)



Проблемы и задачи

- Выбор универсального оптимального порога?
- Исследование устойчивости матрицы нечеткого отношения предпочтения
- Построение “дружественного” интерфейса блока сличения списков