

**Государственное образовательное учреждение
Высшего профессионального образования
«Оренбургский государственный университет»**

Рыбина Алена Игоревна

**Автоматизация процесса определения
релевантности текста информационному запросу
методом латентно-семантического анализа**

230100.68 – Информатика и вычислительная техника

Научный руководитель
кандидат технических наук,
Цыганков А.С.

Оренбург 2015

ПОСТАНОВКА ЗАДАЧИ ИССЛЕДОВАНИЙ

Объект - информационное и программное обеспечение поисковой системы.

Предмет - методы, модели и средства определения релевантности текста поисковому запросу.

Границы исследования - осуществление процесса поиска текстовой информации.

Цель: Разработка автоматизированной поисковой системы с повышенной точностью поиска соответствия информационному запросу.

Задачи :

1. Проведение анализа предметной области, определение существующих и разрабатываемых подходов поисковых механизмов.
2. Определение критериев качественного функционирования системы поиска.
3. Разработка поискового алгоритма на основе латентно-семантического анализа.
4. Создание эффективного поискового механизма.
5. Прототип автоматизированной системы использующей предложенный метод определения релевантности текстов.
6. Результаты экспериментального исследования разработанного прототипа и оценки его эффективности.

СХЕМА ПРОВЕДЕНИЯ ИССЛЕДОВАНИЙ

СИСТЕМНЫЙ АНАЛИЗ ПРОЦЕССА ОПРЕДЕЛЕНИЯ РЕЛЕВАНТНОСТИ ТЕКСТА

1.1 Анализ проблем
процесса определения
релевантности текста

1.2 Анализ аналогов
поисковых алгоритмов

1.3 Концептуальная постановка
задачи исследований и её
формализация

МЕТОДЫ И МОДЕЛИ СЕМАНТИЧЕСКОГО ПРЕДСТАВЛЕНИЯ ТЕКСТА

2.1 Исследование моделей
описания текстового контента

2.2 Развитие модели текстового
контента для задачи поиска

2.3 Разработка алгоритма
семантического
представления текстов

РАЗРАБОТКА СРЕДСТВ ПРОЦЕССА ОПРЕДЕЛЕНИЯ РЕЛЕВАНТНОСТИ ТЕКСТА

3.1 Разработка алгоритма
системы определения
релевантности текста

3.2 Разработка алгоритма
определения оптимальных
параметров

3.3 Разработка алгоритма
выявления латентных связей

ИССЛЕДОВАНИЯ ЭФФЕКТИВНОСТИ СИСТЕМЫ ОПРЕДЕЛЕНИЯ РЕЛЕВАНТНОСТИ ТЕКСТА ИНФОРМАЦИОННОМУ ЗАПРОСУ МЕТОДОМ ЛАТЕНТНО-СЕМАНТИЧЕСКОГО АНАЛИЗА

4.1 Методика оценки эффективности
поиска информации

4.2 Сравнительная оценка
эффективности поиска информации

4.3 Направления
дальнейших
исследований

ОСОБЕННОСТИ ЭКСПЛУАТАЦИИ ПОИСКОВЫХ СИСТЕМ




Рисунок 1 – динамика роста интернет аудитории и количества доменов





Рисунок 2– Динамика изменения возрастного состава интернет-аудитории

ВОЗРАСТНОЙ СОСТАВ АУДИТОРИИ ИНТЕРНЕТА В РОССИИ



ПО ДАННЫМ TNS WEB INDEX, ДЕКАБРЬ 2014
ЗАМЕРЫ ДЛЯ ВОЗРАСТНОЙ ГРУППЫ СТАРШЕ 64 ЛЕТ ДО 2014 ГОДА НЕ ПРОВОДИЛИСЬ, ПОЭТОМУ НА ДИАГРАММЕ ОНА НЕ ПРЕДСТАВЛЕНА

По данным TNS Web Index, доля пользователей старшей возрастной группы растёт год от года.

Объект исследования: $OI = \{ Mt \{ Mob \{ S \} \}$ (1.1)

где Mt – метод поиска релевантной информации;

Mob – модель объекта исследования;

S – средства поиска информации.

ПРОТИВОРЕЧИЯ ОПРЕДЕЛЕНИЯ РЕЛЕВАНТНОСТИ ТЕКСТА ИНФОРМАЦИОННОМУ ЗАПРОСУ

Проблемы практики

Увеличение количества пользователей сети Internet

Для построения хорошего запроса необходимо уметь использовать специфичный язык запросов поисковых систем.
Обычно пользователь не обладает достаточной квалификацией.

Увеличение количества сайтов и web-документов

Проблемы теории

Методы поиска информации базируются на поиске прямых вхождений слов из запроса в текст и не в полной мере учитывают их семантическое содержание web-документов

Существующие алгоритмы требуют существенных ресурсов, что снижает производительность поисковых систем

Противоречие между количеством web-Документов в совокупности с низким уровнем квалификации пользователей и методами поиска, не учитывающими семантическое содержание документа и чувствительными к использованию специфического языка запросов.

Предмет исследования

$$PI = \{ Mt, Mpr, I \} , \quad (1.2)$$

где *Mt* – методы поиска информации;

Mpr – модель описания текста;

I – объем информации для определения релевантности.

АНАЛИЗ АНАЛОГОВ ПОИСКОВЫХ АЛГОРИТМОВ

КОНЦЕПТУАЛЬНАЯ ПОСТАНОВКА ЗАДАЧИ ИССЛЕДОВАНИЙ И ЕЁ ФОРМАЛИЗАЦИЯ

"Лаборатория Касперского"




Рис. X – Тематика **служебной переписки**



Рис. X – Методы классификации



Рис. X – Подходы к задаче фильтрации

Рис. X – Методы борьбы с НЭС

Целевая функция

где R – ошибки поиска;

$L \in \{L_{et}\}$ – множество web-документов;

$P = (p_1, p_2, p_3, \dots, p_l)$ пространство признаков, характеризующих L ;

A – алгоритм классификации к одному из классов $K \in \{k_1, k_2\}$.

ИССЛЕДОВАНИЯ МОДЕЛЕЙ ОПИСАНИЯ ТЕКСТОВОГО КОНТЕНТА

Векторная модель

t_n – терм (смысловая единица) в n -ом документе D
(слово, понятие, предложение и т.д.)

- множество термов документа D ,


- множество свойств термов t_i в D .

Модель на основе графа

$$D = (t, S)$$

Синтаксическое представление


(дерево зависимостей)



где $S_1..S_n$ – расстояние между словами

Семантическое представление

(семантические сети, семантический граф)




$$D = (P, O)$$

P_n – понятия в тексте

O_n – отношение между понятиями

МОДЕЛЬ WEB-ДОКУМЕНТОВ



Модель web-документа

$$S(p_i) = \langle t_i, w(t_i) \rangle$$

где t – i -ый терм в документе;

p_i – пространство признаков, определяющих сообщение;

$w(t_i)$ – вес термина в документе после удаления стоп-слов.

где S_j – j -ое сообщение электронной корреспонденции;

w_{ij} – вес термина i в сообщении j ;

N – число терминов в сообщении.



$$tf(w, d) = \frac{n_{wd}}{n_d}$$

где n_{wd} – число вхождений слова в документ, n_d – общее число слов в данном тексте;

$$idf(w, D) = \log \frac{|D|}{|(d \supset w)|}$$

где $|D|$ – число текстов в корпусе, а $|(d \supset w)|$ – число текстов, в которых встречается w . Теперь

$$tfidf(w, d, D) = tf(w, d) \times idf(w, D).$$

РАЗРАБОТКА АЛГОРИТМА СЕМАНТИЧЕСКОГО ПРЕДСТАВЛЕНИЯ ТЕКСТОВ

Матрица признаков базы документов L_k

$$L_k = \langle T_k, w(t_j) \rangle$$

где T_k – k -ый терм сообщения;

$w(t_j)$ – вес терма в документе j ;


где L_k – база документов k ;

ω_{ij} – вес терма i в документе j ;

N – число термов в базе;

M – число документов в базе.

РАЗРАБОТКА АЛГОРИТМА СИСТЕМЫ ОПРЕДЕЛЕНИЯ РЕЛЕВАНТНОСТИ ТЕКСТА



Сингулярное разложение матриц

$$A=U S V^T,$$

где U и V^T — ортогональные матрицы размером $n*n$ и $m*m$, соответственно,

а S — диагональная матрица с сингулярными числами матрицы A на диагонали.

Диагональные элементы матрицы S имеют вид:

$$S_1 > S_2 > \dots > S_n > 0$$

РАЗРАБОТКА АЛГОРИТМА ОПРЕДЕЛЕНИЯ ОПТИМАЛЬНЫХ ПАРАМЕТРОВ

- определить влияние параметра K на количество шумов в результирующей матрице корреляций.
- Нахождение оптимального параметра K , при котором количество шумов будет минимально. $f(x) \rightarrow \min_{x \in U}$

	c1	c2	c3	c4	c5	m1	m2	m3	m4
c1	1								
c2	0.19	1							
c3	0.00	0.00	1						
c4	0.00	0.00	0.47	1					
c5	-0.33	0.58	0.00	-0.31	1				
m1	-0.17	-0.30	-0.21	-0.16	-0.17	1			
m2	-0.26	-0.45	-0.32	-0.24	-0.26	0.67	1		
m3	-0.33	-0.58	-0.41	-0.31	-0.33	0.52	0.77	1	
m4	-0.33	-0.19	-0.41	-0.31	-0.33	-0.17	0.26	0.56	1

	c1	c2	c3	c4	c5	m1	m2	m3	m4
c1	1								
c2	0.91	1							
c3	1.00	0.91	1						
c4	1.00	0.88	1.00	1					
c5	0.85	0.99	0.85	0.81	1				
m1	-0.85	-0.56	-0.85	-0.88	-0.45	1			
m2	-0.85	-0.56	-0.85	-0.88	-0.44	1.00	1		
m3	-0.85	-0.56	-0.85	-0.88	-0.44	1.00	1.00	1	
m4	-0.81	-0.50	-0.81	-0.84	-0.37	1.00	1.00	1.00	1

Рисунок 5 – Корреляция в исходной матрице и в преобразованной

$$P(t_k | d_i, w_j) = \frac{P(w_j | t_k) P(t_k | d_i)}{\sum_{l=1}^{|T|} P(w_j | t_l) P(t_l | d_i) + \gamma P_{noise}(w_j | d_i) + \epsilon P_{background}(w_j)}$$

$$P_{noise}(w_j | d_i) = \frac{\gamma P_{noise}(w_j | d_i)}{\sum_{l=1}^{|T|} P(w_j | t_l) P(t_l | d_i) + \gamma P_{noise}(w_j | d_i) + \epsilon P_{background}(w_j)}$$

$$P_{background}(w_j) = \frac{\epsilon P_{background}(w_j)}{\sum_{l=1}^{|T|} P(w_j | t_l) P(t_l | d_i) + \gamma P_{noise}(w_j | d_i) + \epsilon P_{background}(w_j)}$$

РАЗРАБОТКА АЛГОРИТМА ВЫЯВЛЕНИЯ ЛАТЕНТНЫХ СВЯЗЕЙ

ПРОГРАММНЫЙ ПРОЕКТ ПРОТОТИПА СИСТЕМЫ КОНТЕНТНОЙ ФИЛЬТРАЦИИ ЭЛЕКТРОННОЙ КОРРЕСПОНДЕНЦИИ




Рисунок X – Архитектура системы контентной фильтрации




Рисунок X – Диаграмма компонентов программного проекта системы контентной фильтрации

ПРОЕКТ БАЗЫ ДАННЫХ И ИНТЕРФЕЙС СИСТЕМЫ КОНТЕНТНОЙ ФИЛЬТРАЦИИ




Рис. X – Инфологическая модель предметной области






Рис. X – Интерфейс настройки спам-фильтра

Событие	Дата/время	Адрес (кому)	Адрес (от кого)	Тема	Размер	Классифицировано как...
Письмо классифицировано	13.04.2013 09:47:53	Кафедра ПОВТАС	Галкина Наталья [N12k@yandex.ru]	Наталья	561	Легитим
Письмо классифицировано	13.04.2013 12:23:30		юЕТОПЖУПЧБ [chern@mail.osu.ru]	ОПЖУПЧБ	537	Спам
Письмо классифицировано	13.04.2013 12:47:54	Кафедра ПОВТАС	Валеев Артем [valfw@yandex.ru]		270	Легитим
Письмо классифицировано	13.04.2013 13:12:23	Tatarinov, Vitaly V.			1417	Легитим
Письмо классифицировано	13.04.2013 13:12:43	Кафедра ПОВТАС	Александр Чулков [sas.74@bk.ru]	Александр Чулков	852	Легитим
Письмо классифицировано	13.04.2013 12:47:57	Кафедра ПОВТАС	Юрий Фёдоров [sor-55@mail.ru]		212	Легитим
Письмо классифицировано	13.04.2013 14:12:26	Аралбаев Т.З. (ФИТ); Болк	Дырдина Е.В. [dyrdinaev@mail.osu.ru]		593	Легитим
Письмо классифицировано	13.04.2013 14:47:59	rovvt@unpk.osu.ru	library_oit@mail.osu.ru		757	Легитим
Письмо классифицировано	13.04.2013 15:10:00	Кафедра ПОВТАС	Alla Vladova [avladova@mail.ru]	ФДС маги ПИ ТДОД	472	Легитим
Письмо классифицировано	13.04.2013 15:48:00	rovvt@unpk.osu.ru	AIS [ais@mail.osu.ru]	Вручение сертификатов	1092	Легитим

Рис. X – Журнал событий





Рис. X – Интерфейс классификации спам-фильтра

МЕТОДИКА ОЦЕНКИ ЭФФЕКТИВНОСТИ




Рис. X – Методика проведения эксперимента методом k-подмножеств (k-foldes)

Ошибка 1 рода

(принятие решения о легитимности сообщения, когда оно является спамом)

$$\alpha = FN_{sp} / N_{sp}, \quad (8)$$

Ошибка 2 рода

(принятие решения о спамности сообщения когда оно является легитимным)

$$\beta = FP_l / N_l, \quad (9)$$

Мера полноты

(precision)

(оценивает долю верного распознавания относительно всех объектов определенного класса)

(12)

Мера точности

(оценивает долю верных обнаружений относительно всех объектов)

(13)

F мера

(сводная оценка качества классификации)

(15)

N_{sp} – число объектов, относящихся к классу спам;

N_l – число объектов, относящихся к классу легитимных сообщений;

FN_{sp} – число спам-рассылок, классифицированных как легитимное письмо;

FP_l – число легитимных писем, классифицированных как спам-рассылка.

TP_l – число правильно классифицированных легитимных ЭС
($TP_l = N_l - FP_l$)

МЕТОДИКА ПРОВЕДЕНИЯ ИМИТАЦИОННОГО ЭКСПЕРИМЕНТА




Таблица 4.1 – Перечень тестовых сообщений

№	Вид сообщения	Тематика сообщений
1	спам	Пустые сообщения, содержащие только ссылки или вложения.
2	спам	Реклама товаров ()
3	спам	Реклама услуг (юридических, бухгалтерских, строительных, образовательных, туристических, медицинских и проч.)
4	спам	Приглашения на курсы, предложения схем «отмывания» денег, и т.п.
5	легитим	Деловая переписка (со знакомыми пользователями) свободная форма
6	легитим	Деловая переписка (со знакомыми пользователями) приказы, распоряжения и т.п.
7	легитим	Приглашения на участие в грантах, конференциях, выставках и т.п.

Рисунок 4.5 – Схема имитационного эксперимента


Название	Модель ЭС	Вес	Метод сокращения признаков пространства	Выделение устойчивых словосочетаний	Алгоритм классификации
Met1	векторная	Tf-idf	RF	+	нейрон. сеть Art
Met2	векторная	Ltc	RF	+	нейрон. сеть Art
Met3	векторная	Ltc	RF	-	нейрон. сеть Art
Met4	векторная	Ltc	IG	+	нейрон. сеть Art
Met5	векторная	Tf-idf	IG	+	нейрон. сеть Art

Методика оценки результатов имитационного эксперимента

Результатом ИЭ являются определение средних значений двух вероятностных характеристик - вероятности принять решение о легитимности сообщения, когда оно спам (α - **ошибка 1 рода**) и вероятность отвергнуть решение о легитимности сообщения, когда оно легитимно (β - **ошибка 2 рода**), сводной оценки качества классификации (F-мера), полноты и точности.

ОЦЕНКА ЭФФЕКТИВНОСТИ ПРОТОТИПА СИСТЕМЫ СПАМ-ФИЛЬТРАЦИИ

оценка качества классификации (уровень ошибки I и II рода)



оценка качества классификации по трем метрикам (полнота, точность, F-мера)




Рис. X – Сравнительная оценка **эффективности** предложенного спам-фильтра и фильтра на основе байесовского классификатора

Рис. X – Результаты имитационного эксперимента

ОСНОВНЫЕ РЕЗУЛЬТАТЫ ДИССЕРТАЦИОННОГО ИССЛЕДОВАНИЯ

1 Научная новизна модели ЭС заключается в применении меры значимости для определения веса признаков в ЭС (термов) позволяющей сократить характерный разброс в частотах различных термов

Во первых, предложен комбинированный метод сокращения признакового пространства, основанный на том, что для каждого терма в сообщениях определенного класса вычисляется величина, характеризующая значимость терма для определенного класса (spam\legitim)

Во вторых, предложенная методика выделения устойчивых словосочетаний позволяет без потери смыслового содержания выделить термы характеризующие данное сообщение(класс), тем самым выделить признаки легитимности сообщения в отличии от существующих фильтров учитывающих только признаки спама.

2 Новизна методики и алгоритмов фильтрации НЭС заключается в развитии нейросетевых методов классификации и новом практическом применении нейронной сети ART для осуществления идентификации несанкционированных рассылок электронной почты.

АПРОБАЦИЯ, ПУБЛИКАЦИИ

Научные и практические результаты диссертационных исследований

обсуждались и получили одобрение на 5-ти всероссийских научно-практических конференциях с международным участием (ОГУ 2003- 2008 гг.; СПГТУ 2008 г.) и 3-х региональных научных семинарах «Актуальные вопросы информационных технологий теории управления» (ВУ ВПВО 2006 -2008 гг.);

опубликованы в 10-ти печатных работах, одна из которых – в издании, определенном ВАК России для опубликования научных результатов диссертаций на соискание ученых степеней, в 2-х свидетельствах о государственной регистрации программ, а также в четырех отчетах о НИР на спецтемы.

НАПРАВЛЕНИЯ ДАЛЬНЕЙШИХ ИССЛЕДОВАНИЙ

Анализ среды Internet как предпосылки НСР	Исследования механизмов спам-рассылок	Разработка методов и средств спам-фильтрации
Анализ системного и прикладного ПО. Исследование сетевого оборудования и анализ протоколов. Анализ современных типовых технологии получения информации о спам-рассылках.	Систематизация и моделирование механизмов спам-рассылок и других аномальных событий. Модели спам-рассылок, интегрированных с информационными атаками. Создание механизмов адаптивной защиты	Обнаружение и предотвращение спам-рассылок. Обнаружение и защита от сетевых вирусов Активное противоборство спам-воздействиям Анализ рисков возникновения спам-атак, их последствий и определение фактической степени необходимой защиты.

