

Исследование средств сбора и поиска информации на заданном множестве Web-сайтов (на примере информационных порталов EGEE и НТУУ «КПИ»)

работа студента группы ДА-42м

Шафрая Андрея Юрьевича

# Модуль поиска

- Задачи
  - Обработка текста на странице
  - Индексация данных
  - Поиск по собранным данным

# Модуль поиска в общей системе



# Критерии оценки систем индексирования и поиска

- скорость индексирования
- скорость переиндексации
- размер базы и скорость поиска
- работа с разными языками и стемминг

# Сравнительные характеристики систем индексирования и поиска

	<b>Sphinx</b>	<b>Apache Lucene</b>	<b>Xapian</b>
<b>Лицензия</b>	GPL 2 или коммерческая	Apache License 2.0	GPL
<b>Тип</b>	отдельный сервер или MySQL storage engine	отдельный сервер или сервлет, встраиваемая библиотека	встраиваемая библиотека
<b>Платформа</b>	C++	Java (реализован также на PHP, C#/.NET, Perl, Ruby, Python)	C++
<b>Варианты поиска</b>	булевый поиск, поиск по фразам, учёт близости слов	булевый поиск, поиск по фразам, учёт близости слов, поиск по маске	булевый поиск, поиск по фразам, поиск с ранжированием, поиск по маске, поиск по синонимам

# Сравнительные характеристики систем индексирования и поиска

	Sphinx	Apache Lucene	Xapian
<b>Поддержка языков</b>	встроенный английский и русский стемминг, soundex для реализации морфологии	отсутствует морфология, есть стемминг (Snowball) и анализаторы для ряда языков (включая русский)	отсутствует морфология, есть стемминг для ряда языков (включая русский), проверка правописания в поисковых запросах
<b>Размер индекса/скорость</b>	индексация около 10 Мб/сек (зависит от CPU), поиск около 0.1 сек/~2 – 4 Гб индекса, поддерживает размеры индекса в сотни Гб и сотни миллионов документов.	около 20 Мб/минута, размер индексных файлов ограничен 2 Гб (на 32-bit ОС). Есть возможности параллельного поиска по нескольким индексам и кластеризация	тесты скорости на офф. сайте отсутствуют. Известны работающие инсталляции на 1.5 Тб индекса

# Сравнительные характеристики систем индексирования и поиска

	MySQL	Lucene	Sphinx
Индексация, min	1627	176	84
Индекс, MB	3011	6328	2850
Match all, ms/q	286	30	22
Match phrase, ms/q	3692	29	21
Match bool top-20, ms/q	24	29	13

# Результаты работы модуля поиска

## Пошук на множині сайтів НТУУ"КПІ"

Рядок пошуку: Системного Проектування

Вивести кількість результатів

Результати 1 - 30 на запит Системного Проектування (0.2235 сек)

<http://cad.kpi.ua>

Кафедра Системного Проектування Національний Технічний Університет України КПІ ННК Інститут  
Прикладного Системного Аналізу

## Пошук на множині сайтів НТУУ"КПІ"

Рядок пошуку: "Системного Проектування"

Вивести кількість результатів

Результати 1 - 30 на запит "Системного Проектування" (0.2145 сек)

<http://cad.kpi.ua>

Кафедра Системного Проектування Національний Технічний Університет України КПІ ННК Інститут  
Прикладного Системного Аналізу

## Пошук на множині сайтів НТУУ"КПІ"

Рядок пошуку: "прикладного аналізу"

Вивести кількість результатів

Результати 0 - 0 на запит "прикладного аналізу" (0.0051 сек)

# Поиск по структурам Semantic Web

Поисковый запрос:  
author:Ivanov

id	fileId	attribute	value
1	1	author	Ivanov I.
2	1	ISBN	978-5-17-063541-2
3	1	Name	Integrated Circuits Architecture

1. Ivanov I. Integrated Circuits Architecture - 978-5-17-063541-2

# Выводы

- ▶ Исследованы различные системы поиска информации на множестве заданных сайтов.
- ▶ Разработан и реализован модуль поиска информации для комплексной системы.
- ▶ Решены следующие задачи:
  - ▶ Выбор механизма индексации и поиска, удовлетворяющего соотношению эффективности и скорости поиска и вычислительных мощностей, которые для этого необходимы.
  - ▶ Осуществлен полнотекстовый поиск информации, собранной с заданных веб-сайтов.
  - ▶ Достижение высокой скорости поиска информации.
  - ▶ Построение пользовательского интерфейса для поиска.



**Спасибо за внимание**