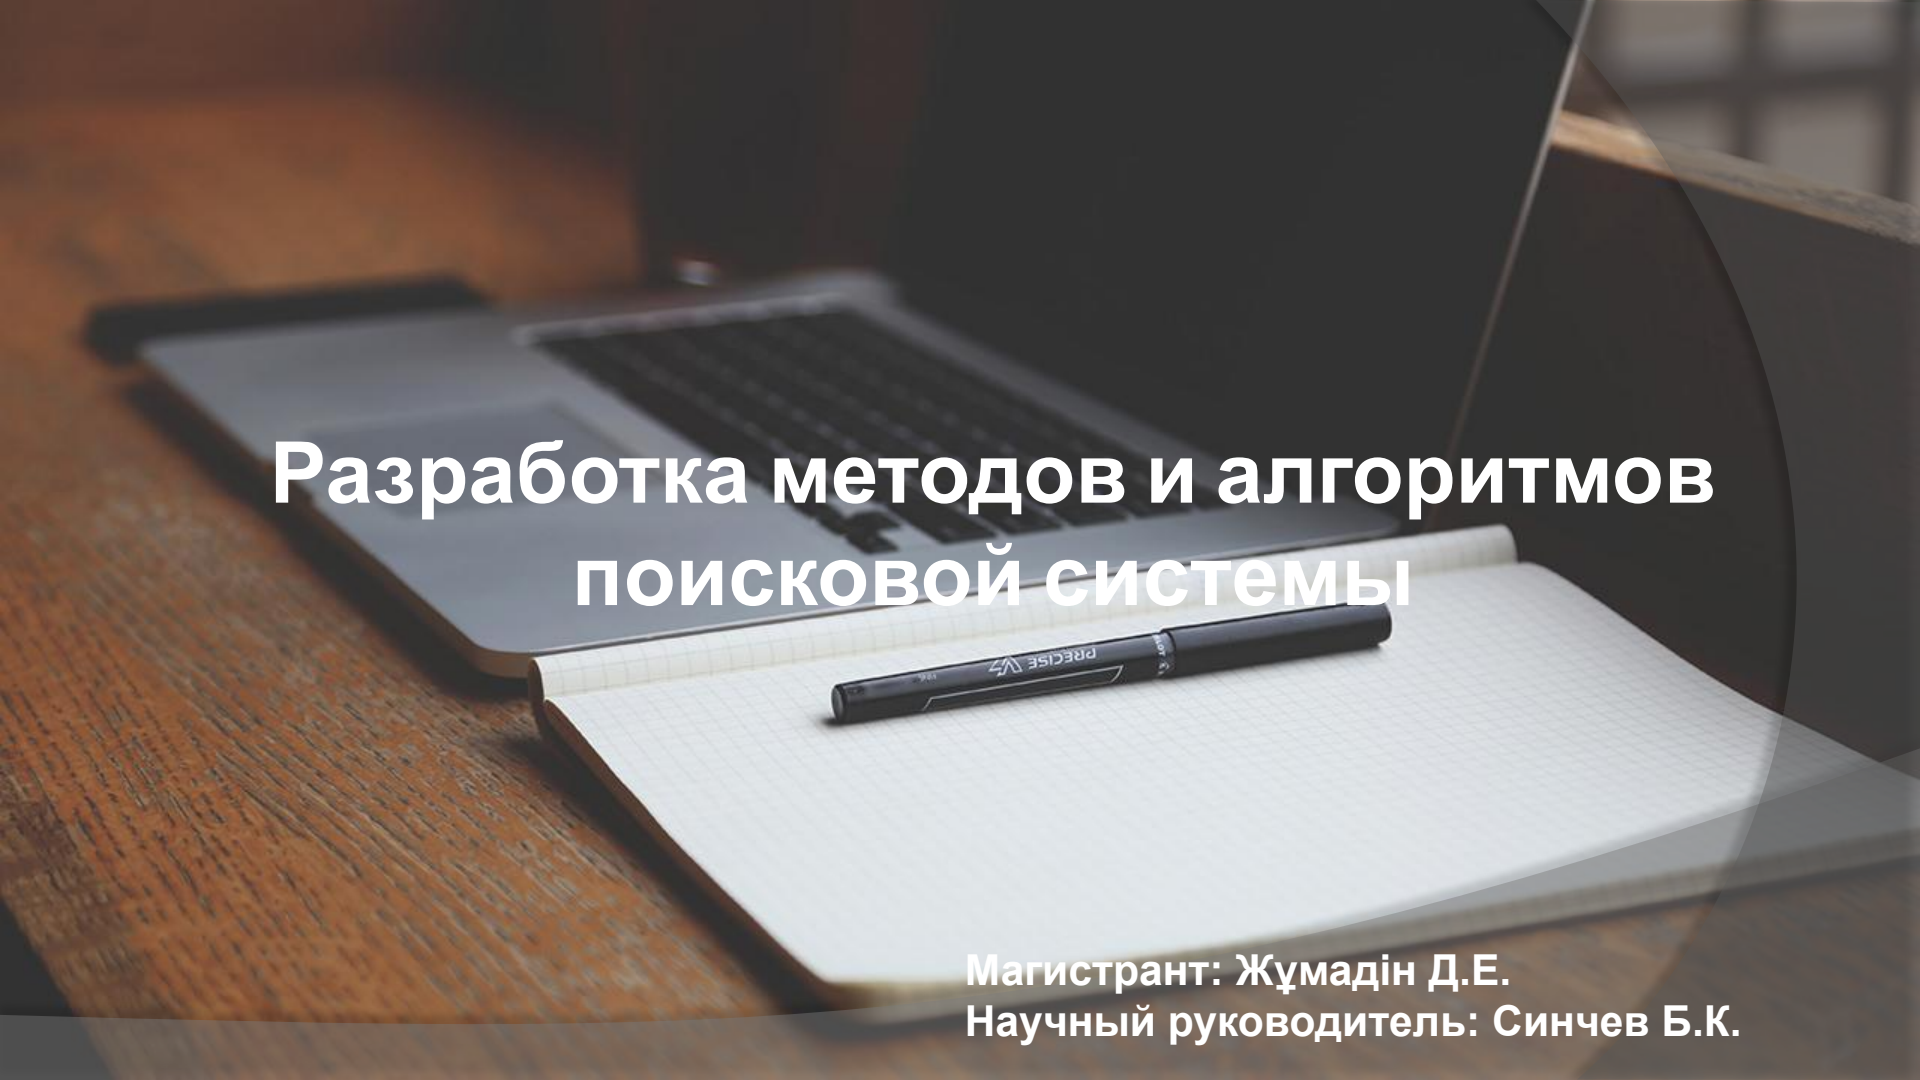

Разработка методов и алгоритмов поисковой системы

Магистрант: Жұмадін Д.Е.
Научный руководитель: Синчев Б.К.

Содержание

- Актуальность темы диссертации
- Цели и задачи диссертации
- Определение объекта и предмета исследования
- Научная новизна
- Методология исследования
- Заключение

АКТУАЛЬНОСТЬ ТЕМЫ

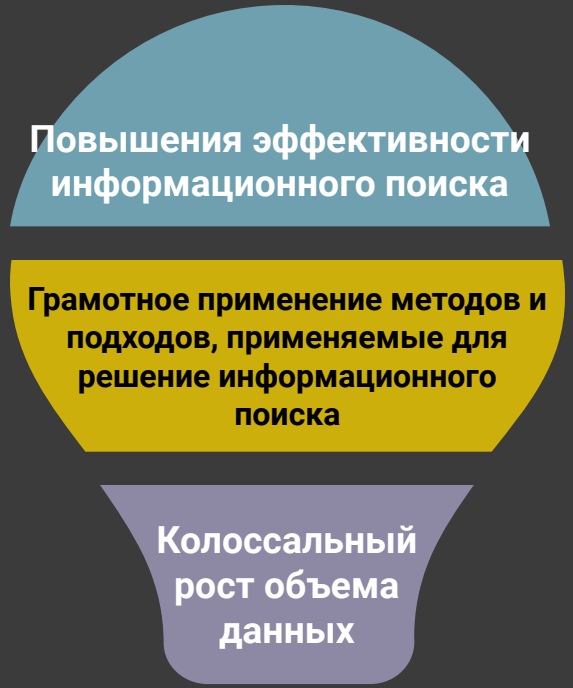

Цели и задачи

Цель

Целью диссертационного исследования является разработка основных методов и программных средств поиска информации для ИПС

Задачи

- исследование основных подходов и методов поиска
- изучение основных характеристик и особенностей ИПС
- изучение различных методов поиска в ИПС

Определение объекта и предмета исследования

- **Объектом исследования** в данной работе является основные методы поиска информации в ИПС
- **Предметом исследования** являются методы, применяемые для решения задач информационного поиска

Научная новизна

Предложен метод информационного-поиска, который позволяет существенно повысить эффективность и точность информационного поиска, а также удобочитаемость результатов поиска.

Базовые отличия СВД и ИПС

	СВД	ИПС
соответствие данных поисковому запросу	точное	частичное
классификация документов	детерминированная	вероятностная
язык запросов	искусственный	естественный
критерии выборки документов	булева функция релевантности	вероятностная функция релевантности
устойчивость к ошибкам в данных и запросах	неустойчивы	устойчивы

Существующие информационные системы, работающие с электронными тестовыми документами, можно условно разделить на две категории: информационно-поисковые системы (information retrieval systems), и системы выборки данных (data retrieval systems).

Методы поиска данных и Постановка задачи

Все алгоритмы поиска делятся на
- поиск в неупорядоченном множестве данных;
- поиск в упорядоченном множестве данных.

Упорядоченность – наличие отсортированного ключевого поля.

Цель сортировки – облегчить последующий поиск элементов в отсортированном множестве при обработке данных.

Задачу поиска можно сформулировать так: найти один или несколько элементов в множестве, причем искомые элементы должны обладать определенным свойством.

Анализ методов поиска данных

Последователь-ный поиск

Последовательный поиск

Начать с начала и продолжать, пока не будет найден искомый ключ, затем остановиться - это простейший из алгоритмов поиска. Этот алгоритм не очень эффективен, однако он работает на произвольном списке.

Процедура SequentialSearch выполняет последовательный поиск элемента z в массиве A[1..n].

```
SequentialSearch(A, z, n)
(1) for i ←1 to n
(2) do if z = A[i].key
(3) then return i
(4) return 0
```

Последовательный поиск

Анализ наихудшего случая.

У алгоритма последовательного поиска два наихудших случая.

1. **В первом случае целевой элемент стоит в списке последним.**
2. **Во втором его вовсе нет в списке.**

В обоих случаях алгоритм выполнит n сравнений.

Анализ среднего случая.

Целевое значение может занимать одно из n возможных положений. Будем предполагать, что все эти положения равновероятны.

Анализ методов поиска данных

Логарифмический (бинарный) поиск

Пусть упорядоченный массив $x(1{:}n)$ содержит, например, элементы 5, 7, 11, 18, 26, 32, 44, 57, 81, 90, 94, 97, 107, 116, 129, 147, 179 и пусть задан аргумент поиска *key*, равный, например, 129.

Идея алгоритма бинарного поиска такова:

- сравнить аргумент поиска *key* со значением среднего элемента $x(mid)$ массива x, где $mid = [n/2]$, а $[c]$ – целая часть числа c;
- если они равны, то поиск завершен, иначе, если $key < x(mid)$, выполнить аналогичным образом поиск в позициях массива x, предшествующих позиции *mid*, в противном случае, если $key \geq x(mid)$, выполнить аналогичным образом поиск в позициях массива x, следующих за позицией *mid*.

Логарифмический (бинарный или метод делением пополам) поиск

```
BinarySearch(A, z, n)
(1) p←1
(2) r←n
(3) while p ≤ r do
(4) q← [(p+r)/2]
(5) if A[q].key = z
(6) then return q
(7) else if A[q].key < z
(8) then p←q+1
(9) else r←q-1
(10) return 0
```

Исключить из дальнейшего рассмотрения часть массива позволяет тот факт, что массив упорядочен.

Процедура BinarySearch выполняет бинарный поиск элемента z в отсортированном массиве A[1..n].

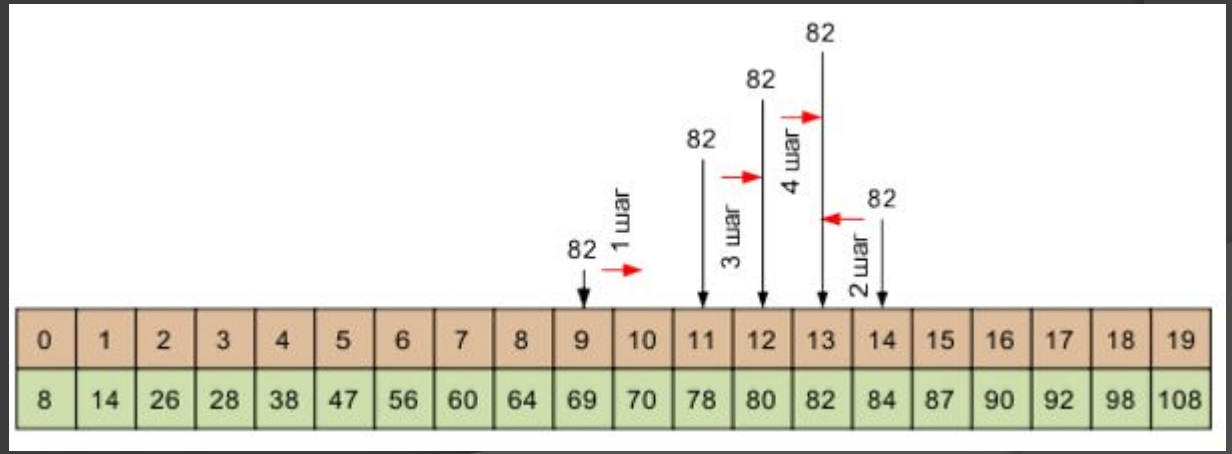

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
8	14	26	28	38	47	56	60	64	69	70	78	80	82	84	87	90	92	98	108

Логарифмический (бинарный или метод делением пополам) поиск

Анализ наихудшего случая.

Поскольку алгоритм всякий раз делит список пополам, будем предполагать при анализе, что $n = 2^k - 1$ для некоторого k. Ясно, что на некотором проходе цикл имеет дело со списком из $2^j - 1$ элементов.

Анализ среднего случая.

Рассмотрим два случая. В первом случае целевое значение наверняка содержится в списке, а во втором его может там и не быть. В первом случае у целевого значения n возможных положений.

Результат выполнения

Последовательный поиск

Логарифмический поиск

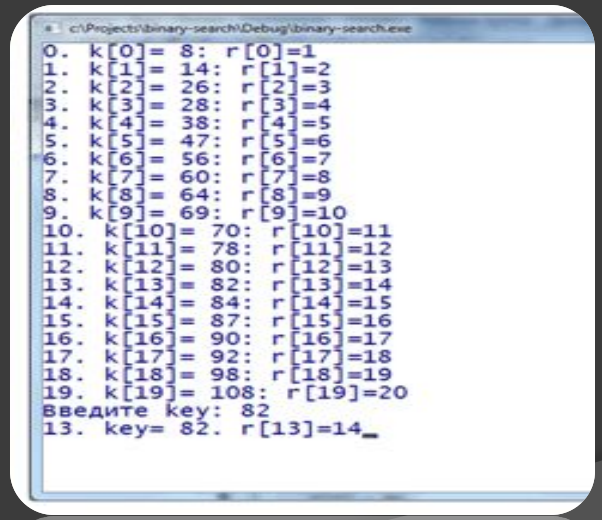

Заключение

В результате выполнения работы сравним алгоритмы последовательного и бинарного поиска. Пусть файл, в котором выполняется поиск, отсортирован и содержит 1024 (210) элемента. В случае последовательного поиска наибольшее число итераций будет равно 1024, а бинарного – 11. То есть разница в два порядка.
Сравним теперь временные затраты на поиск в случае неотсортированного файла. При последовательном поиске максимальное число итераций, разумеется, сохраняется. Бинарный поиск неприменим. Выполним, однако, быструю сортировку файла.

В этом исследовании мы показали, что если файл неотсортирован и в процессе вычислений задача поиска в файле возникает сравнительно, то можно применять последовательный поиск, в противном случае более целесообразно прежде отсортировать файл и при вычислениях применять бинарный поиск.

Спасибо за внимание!