

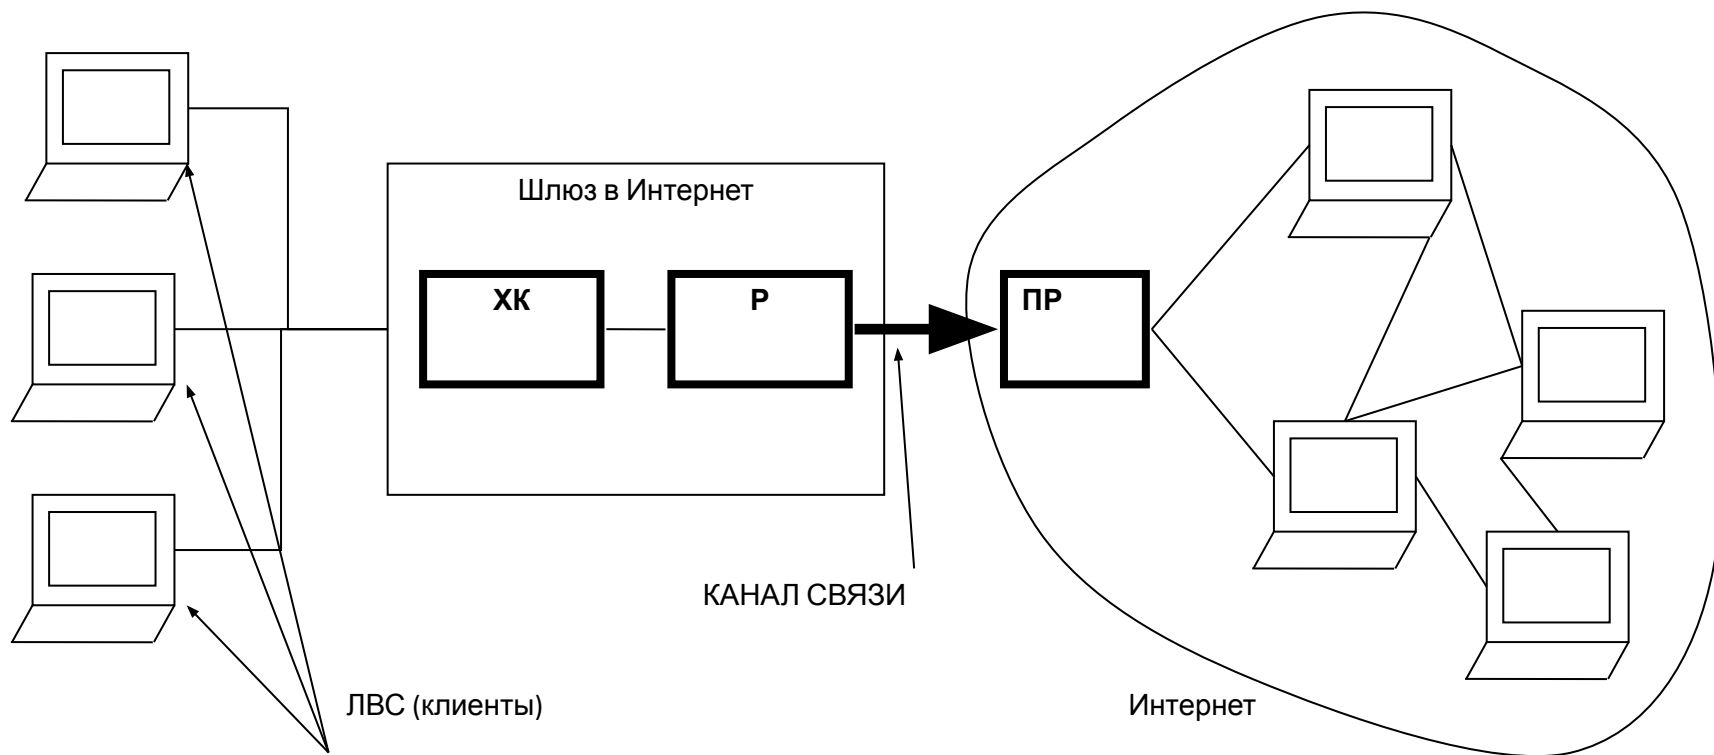


Поиск информации в интернете

Занятие 4. Теория поиска информации



Информация о структуре Internet





Информация о структуре Internet

- ХК: хост-компьютер (сервер) — мощная ЭВМ, обеспечивающая выполнение запросов клиентов;
- Р: роутер (маршрутизатор) — ЭВМ, управляющая адресацией информации;
- ПР: провайдер — сервисная фирма, обеспечивающая доступ в Интернет (обычно платный) и имеющая мощный компьютер или комплекс.



Информация о структуре Internet

Работа в **Интернет** может выполняться в нескольких режимах, поддерживаемых соответствующими протоколами обмена данных. Это следующие режимы:

- 1. Терминальный режим - программы клиентов выполняются на узловом сервере сети. Протокол **TCP/IP**.
- 2. Интерактивный (dialup-IP) **SLIP/PPP**.
- 3. Пакетный. Протокол **UUCP**.



Информация о структуре Internet

Наиболее часто используется протокол **TCP/IP**, где **TCP** - обеспечивает передачу сообщений фрагментами, сборку и проверку переданного документа; **IP** — обеспечивает доставку информации конкретному адресату, т.е. каждый ХК в сети имеет свой уникальный **IP-адрес** в виде записи, состоящей из четырёх десятичных чисел (от 0 до 255), разделённых точками (в случае версии протокола IPv4), например, 192.168.1.254 или (в случае IPv6) в виде записи, состоящей из восьми групп, разделённых двоеточием, состоящих из четырёх шестнадцатеричных цифр, например, fe80:0:0:0:200:f8ff:fe21:67cf.



Информация о структуре Internet

Петя записал IP-адрес школьного сервера на листке бумаги и положил его в карман куртки. Петина мама случайно постирала куртку вместе с запиской. После стирки Петя обнаружил в кармане четыре обрывка с фрагментами IP-адреса. Эти фрагменты обозначены буквами А, Б, В и Г. Восстановите IP-адрес.

В ответе укажите последовательность букв, обозначающих фрагменты, в порядке, соответствующем IP-адресу.

.64	3.13	3.133	20
А	Б	В	Г

Пользователь сети (организация или частное лицо) в Интернет идентифицируется именем пользователя и именем домена, разделенных знаком @:

XXXXXX.XXX@XXXXX.XXX



Информация о структуре Internet

Интернет предоставляет следующие возможности:

- Поиск и просмотр информации (**WWW**).
- Доступ к удаленным базам данных (**WAIS**).
- Связь и удаленный доступ к другим ПК (**Telnet, RDP**).
- Группы новостей, подписки и т.д. (**RSS**)
- Средства, в которых пользователи могут направлять свои сообщения и знакомиться с имеющимися (**форумы, социальные сети**).
- Электронная почта (**POP3, IMAP**).
- Разговор текстом на экране в режиме реального времени (**IRC, ICQ, Skype**)
- Пересылка файлов (**FTP, P2P**).



Информация о структуре Internet

Интернет предоставляет следующие возможности:

- Поиск и просмотр информации (**WWW**).
- Доступ к удаленным базам данных (**WAIS**).
- Связь и удаленный доступ к другим ПК (**Telnet, RDP**).
- Группы новостей, подписки и т.д. (**RSS**)
- Средства, в которых пользователи могут направлять свои сообщения и знакомиться с имеющимися (**форумы, социальные сети**).
- Электронная почта (**POP3, IMAP**).
- Разговор текстом на экране в режиме реального времени (**IRC, ICQ, Skype**)
- Пересылка файлов (**FTP, P2P**).



Информация о структуре Internet

Браузеры постоянно развивались со времени зарождения Всемирной паутины и с её ростом становились всё более востребованными программами. Ныне браузер — комплексное приложение для обработки и вывода разных составляющих веб-страницы и для предоставления интерфейса между веб-сайтом и его посетителем. Практически все популярные браузеры распространяются бесплатно или «в комплекте» с другими приложениями: *Internet Explorer* (совместно с Microsoft Windows), *Mozilla Firefox* (бесплатно), *Safari* (совместно с Mac OS X и бесплатно для Microsoft Windows), *Opera* (бесплатно начиная с версии 8.50), *Google Chrome* (бесплатно), *Avant* (бесплатно).



Теория поиска информации

- Прежде чем мы обратимся к ближайшему рассмотрению Поисковых систем, необходимо рассмотреть **процесс поиска информации в теории.**
- Начнем с **устройства** поисковой машины:

Так работает поисковая машина





«Паук» (*spider*)

- Программа, которая **загружает в поисковую машину web-страницы.**
- Работает аналогично браузеру, установленному на компьютере пользователя, но ничего не отображает ни на каком экране.
- Передает в поисковую систему **HTML-код документа.**



«Червяк» (*crawler*)

- Программа, способная найти на web-странице **все ссылки** на другие страницы.
- Ее задача – **определить, куда дальше должен «ползти» «паук»**, руководствуясь ссылками или заранее заданным списком адресов.



Индексатор (Indexer)

- Программа, которая «разбирает» **web-страницу на составные части** и анализирует их.
- Вычленяются и анализируются заголовки, ссылки, текст документов.
- Отдельно анализируется текст, набранный полужирным шрифтом, курсивом и т.п.



База данных (database)

- **Хранилище всех данных**, которые поисковая система загружает и анализирует.
- **Требует огромных ресурсов** как для хранения, так и для последующей обработки.



Система выдачи результатов поиска (Search Engine Results Engine)

- Программа, которая решает, какие страницы **удовлетворяют запросу** пользователя и в какой степени.
- Именно с этой частью поисковой машины «общается» пользователь.



«Паук» и «червяк»

- Первые две программы, работающие «в связке», часто называют **поисковый робот** или **НТТР-робот**.



Работа ПС

- Таким образом, после получения запроса ПС анализирует ту информацию, которую **собрала ранее**.
- **Плюсы:** многократно повышается скорость обработки запроса.
- **Минусы:** область поиска ограничена внутренними ресурсами ПС, информация в базе данных быстро устаревает.




Индексация и индекс

- Процесс загрузки информации из интернета и предварительного анализа ее поисковой машиной называют **индексацией**.
- Саму базу данных ПС, в которой храниться вся информация – **индекс**.



Индексация

- Глубина индексации может быть **разной**.
- Полные тексты документов, хранящихся на сайте, в базу данных копируются не всегда, иногда поисковые роботы ограничиваются **урезанными версиями** или вообще **только заголовками**.



Механизмы и алгоритмы поиска



Алгоритмы поиска

- Каждая ПС использует свой алгоритм поиска и его детали представляют собой **ноу-хау разработчиков** поисковика.
- **Алгоритм поиска** – метод, руководствуясь которым ПС принимает решение, включать или не включать ссылку на web-страницу в результаты поиска.



Закономерности поиска

- Некоторые из закономерностей поиска информации были описаны профессором филологии из Гарварда **Джорджем Зипфом** в 1949 году.
- Без учета собранных им закономерностей сегодня **не способна работать** ни одна система автоматического поиска информации.



Законы Зипфа

- Зипф заметил, что **длинные слова встречаются в текстах любого языка реже, чем короткие.**
- Это по всей видимости связано с природой человека и вообще любого живого существа.
- На основе этого наблюдения Зипф вывел **два закона.**



Первый закон Zipфа

- Первый закон связывает **частоту появления (вхождения)** того или иного слова с **рангом** этой частоты.
- Наиболее часто встречающимся словам присваивается ранг, равный **единице**.
- Тем словам, что встречаются реже – ранг, равный **двойке** и т.п.



Первый закон Зипфа

- Зипф обнаружил, что произведение частоты вхождения слова и его ранга является постоянной величиной.
- Такая зависимость обычно отображается гиперболой.
- Значение константы Зипфа для разных языков различно, но внутри одной языковой группы оно остается неизменным.




Первый закон Zipфа

- Частота появления (вхождения) того или иного слова является отношением количества появления слова к общему количеству слов в тексте.
- Таким образом, частота слова **не может быть больше единицы** и составляет в реальности сотые и тысячные доли.



Первый закон Zipфа

- Для русского языка константа равна примерно **0,06-0,07**.






Первый закон Зипфа

- Примеры работы закона:
 - Если наиболее распространенное слово встречается в тексте **100 раз**, то следующее по распространенности встретится не 99 и не 90 раз, а **примерно 50!**
 - Самое часто встречаемое слово в английском языке **the** употребляется в **10 раз** чаще, чем слово, имеющее ранг, равный 10. В **100 раз** чаще, чем слово, имеющее ранг 100 и т.д.



Второй закон Зипфа

- Зипф определил, что **частота вхождения слов** и **количество слов, входящих в текст с данной частотой**, тоже взаимосвязаны.





Второй закон Зипфа

- Получившая кривая будет сохранять свои параметры для **всех текстов** в пределах одного языка.
- С другой стороны, **на каком бы языке** текст ни был написан, форма кривой Зипфа останется неизменной. Отличаться будут лишь коэффициенты.



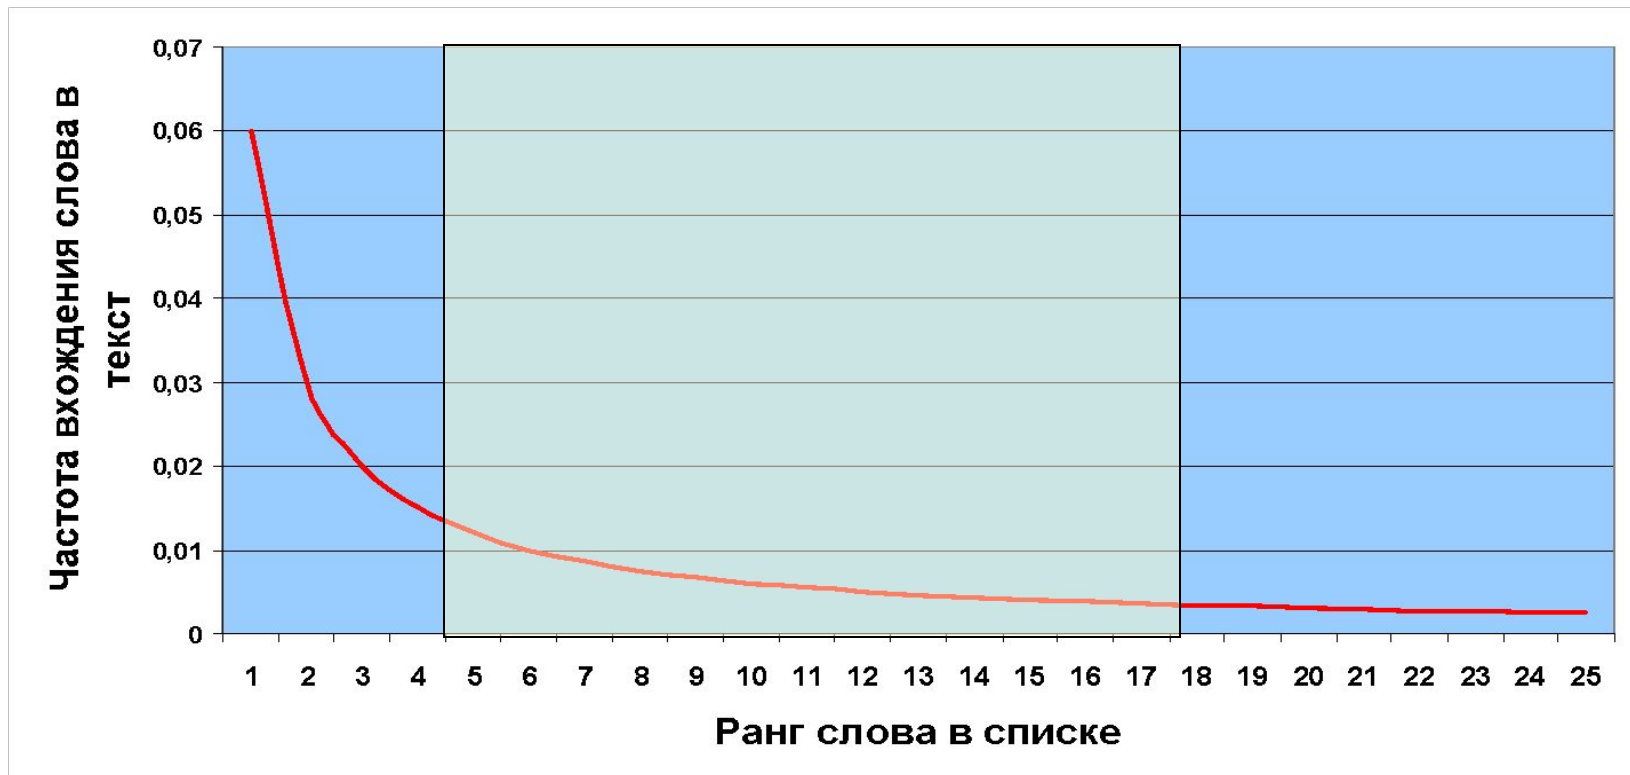
Следствия законов Зипфа

- Законы Зипфа **универсальны**. Они применимы не только к текстам.
- В аналогичную форму выливается, например, зависимость между **количеством городов** и **числом проживающих в них жителей**.
- Характеристики **популярности ресурсов интернета** отвечают законам Зипфа.
- В законах Зипфа отражается «человеческое» происхождение объектов.



Как ПС используют законы Zipf'a


- Рассмотрим график первого закона:





Как ПС используют законы Zipf'a

- Из анализа графика можно предположить, что наиболее значимые для текста слова лежат в средней части графика.





Центральная часть графика

- Центральная зона графика содержит термины, наиболее **характерные** для данного текста.
- Они в совокупности выражают **специфичность текста**, отличие его от других, охватывают его основное содержание.



Левая и правая часть графика

- Действительно, наиболее **часто встречаемые** слова – слева – это предлоги, местоимения, артикли и т.д.
- Справа – **редко встречаемые** слова. Они не несут в большинстве случаев особого смыслового значения.
- Хотя иногда, они, наоборот, бывают **весьма важны** (об этом чуть позже).



Значимые слова

- Каждая ПС по-своему решает, какие слова отнести к наиболее значимым.
- Однако, если к числу значимых будет отнесены слишком **много слов**, то важные термины будут забиты «шумом» случайных слов.
- Если значимых слов будет слишком **мало**, то есть риск потерять главное.



Стоп-слова

- Для того, чтобы безошибочно сузить диапазон значимых слов, создается словарь «бесполезных» слов или **«СТОП-СЛОВ»**.
- Словарь этих слов («стоп-лист») содержит, например, **артикли и предлоги, частицы и личные местоимения**.



Весовой коэффициент

- При определении значимых слов применяется и т.н. «**весовой коэффициент**».
- **Часто встречаемое слово** имеет весовой коэффициент, близкий к нулю.
- **Слово, встречаемое редко**, - весьма высокий коэффициент.



Весовой коэффициент

- Параметр, определяющий «весовой коэффициент», называется **инверсная частота термина**.
- ПС может вычислять «весовой коэффициент» с учетом местоположения слова внутри документа, взаимного расположения разных слов, морфологических особенностей и т.п.



Принцип работы современной ПС

- Современные ПС имеют **пространственно-векторную модель** построения базы данных.
- Она позволяет получить результат, отвечающий запросу даже в том случае, когда в найденном документе **не окажется ни одного ключевого слова!**



Принцип работы современной ПС

- Это достигается благодаря тому, что все документы базы располагаются в **виртуальном многомерном пространстве**.
- **Координаты** каждого документа зависят от содержащихся в нем терминов, их весовых коэффициентов, положения терминов внутри документа и т.п.
- Таким образом, документы с похожим набором терминов оказываются в этом пространстве **поблизости** и ПС их выдает в ответ на запрос.



Полнота и точность поиска



Релевантность

- **Релевантным** называется документ, имеющий отношение к сделанному Вами запросу, т.е. формально содержащий запрашиваемую Вами информацию.
- Англ. **relevant** – «подходящий, относящийся к делу».



Релевантность

- Конкретное общепринятое определение релевантности еще не сложилось.
- «**Экономический словарь**» (www.km.ru) толкует релевантность как «смысловое соответствие между информационным запросом и полученным сообщением».
- **Яндекс:** «мера соответствия результатов поиска задаче, поставленной в запросе».



Релевантность

- В то же время, на Яндексe говорится:
 - «При поиске в интернете важны две составляющие – **полнота** (ничего не потеряно) и **точность** (не найдено ничего лишнего). Обычно все это называют одним словом – **релевантность**».



Полнота поиска

- Коэффициентом полноты поиска называют отношение количества полученных релевантных документов к общему количеству существующих в базе данных релевантных документов:

$$\text{Коэф. полноты поиска} = \frac{\text{Полученные релевантные документы}}{\text{Общее количество релевантных документов в базе данных ПС}}$$



Полнота поиска

- В идеальной ПС коэффициент полноты поиска = 1.
- А противоположный ему коэффициент потерь информации = 0.
- В реальности коэффициент полноты поиска = 0,7-0,9



Точность поиска

- Коэффициентом точности поиска называют отношение количества релевантных результатов к общему количеству документов, содержащихся в ответе ПС на запрос:

$$\text{Коэф. точности поиска} = \frac{\text{Количество релевантных документов}}{\text{Общее количество документов в ответе ПС на запрос}}$$



Точность поиска

- В идеальной ПС коэффициент точности поиска = 1.
- А противоположный ему коэффициент поискового шума = 0.
- В реальности коэффициент точности поиска = 0,1-1



Полнота и точность

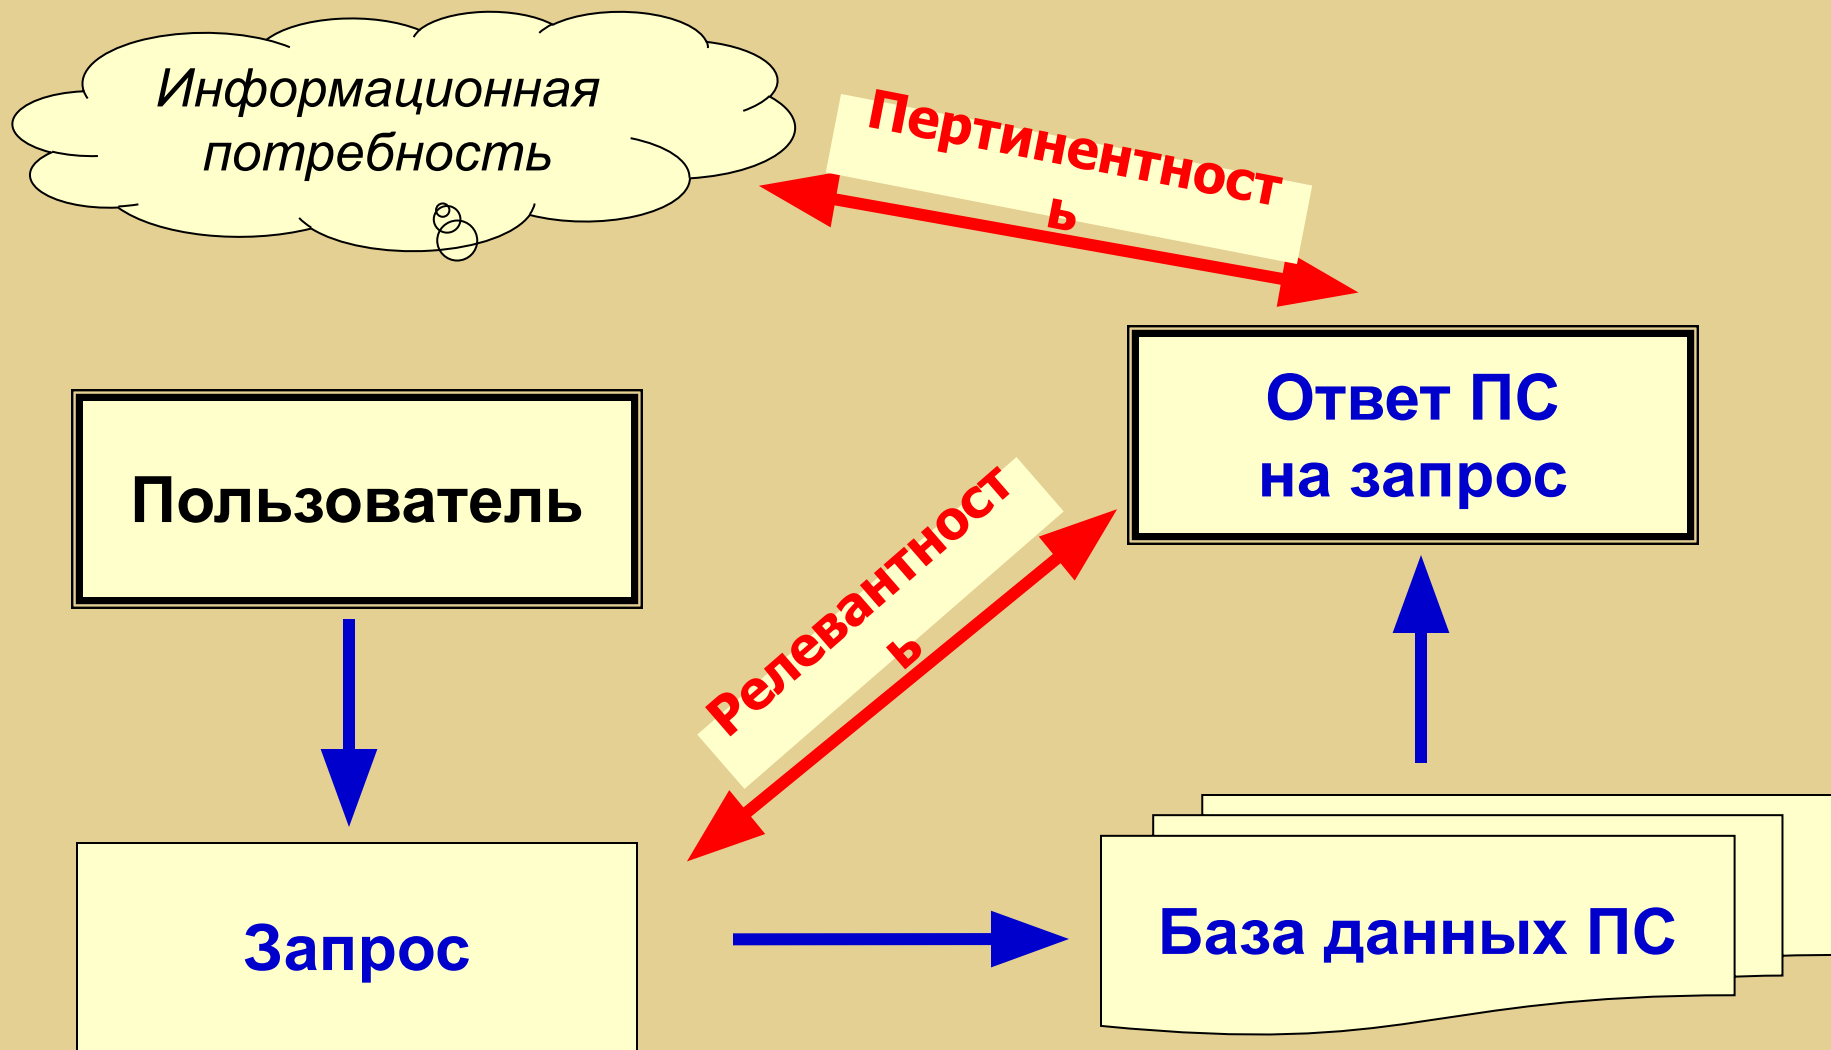
- Нередко количество размещенных в интернете релевантных пользователю документов может составлять десятки тысяч.
- В то же время релевантная информация в них совпадает, и пользователю достаточно изучить лишь **несколько документов** из числа найденных.
- Таким образом, полнота в сравнении с точностью является **второстепенным критерием качества информационного поиска.**



Пертинентность

- На практике используется еще и неформальное понятие – **пертинентность**.
- Это соотношение объема полезной для пользователя информации к объему полученной.
- Зачастую это соотношение имеет **решающее значение**.

Релевантность и пертинентность






Повышение pertinентности

- Средства повышения pertinентности:
 - уточнение формулировок запросов,
 - ранжирование по весовым критериям,
 - ограничение числа выданных в результате поиска документов.



Пертинентность

- Проблеме **пертинентности** уделяется большое внимание в современных ПС.
- Так, ПС Google реализовала алгоритмы достижения **неформальной релевантности** (пертинентности) и благодаря этому стала самой популярной ПС в интернете.



Морфологический анализ



Морфологический анализ

- Почти все современные ПС **учитывают изменения слова** в поиске документов.
- Указывая в строке поиска слово, мы увидим в результате поиска документы, содержащие **варианты этого слова**, измененные по падежам, числу, спряжению и т.д.




Морфологический анализ

- Для непрофессионалов морфологический анализ – это **удобная функция**.
- Она позволяет производить поиск по **всем вариантам слов сразу** и находить даже документы, где слово используется в другой форме.



Морфологический анализ

- Для профессионального поиска морфологический анализ не всегда пригоден. Он **лишает поиск гибкости.**
- Морфологический анализ может увеличить количество документов, выдаваемых по запросу, но количество релевантной информации **уменьшится.**



Эффективный поиск



Эффективный поиск

- Будем считать, что **эффективность поиска информации** тем выше, чем больше коэффициенты **полноты** и **точности**,
- в то же время – меньше **время** и другие **ресурсы**, затрачиваемые на проведение поиска.



Расширенный поиск

- Многие современные ПС с целью повышения эффективности поиска позволяют вместо простого поиска производить т.н. «расширенный».
- Он доступен по ссылке на странице поиска и представляет собой форму, которую нужно заполнить, ответив на дополнительные вопросы.




Сложный поиск

- Кроме этого возможен и т.н. «сложный» поиск с использованием булевых операторов, то есть поиск с помощью логических операторов.
- Булевый поиск станет темой нашего следующего занятия.




Этапы поисковой процедуры

**Формирование
потребности
в информации**



**Формирование
эффективного
запроса
к ПС**



**Поиск нужной
информации
в ответе ПС**



Формирование потребности

- На этой фазе определяется **цель поиска**, его **стратегия** и **область проведения поиска**.
- Информационные потребности могут относиться к разным областям, но на практике они сводятся к общим шаблонам поиска:



Шаблоны поиска

- Поиск новостей,
- поиск людей,
- поиск предприятий и организаций,
- поиск документов,
- поиск музыки, видео и графики,
- поиск программного обеспечения,
- и т.д.



Формирование запроса

- Вторая часть поисковой процедуры предусматривает **многовариантность подходов** и **решений** при формализации запроса.
- Здесь же решается вопрос о выборе конкретной ПС или каталога.



Формирование запроса

- Основная задача при этом – **формирование эффективного запроса.**
- Основная проблема заключается в том, что в каждой ПС используется **свой информационно-поисковый язык.**
- Хотя у различных языков этого типа много общего, например, схожий набор булевых операций.




Формирование запроса

- В настоящее время не существует единого стандарта языка запросов к ПС, хотя попытки стандартизации ведутся.
- Таким образом, в наших лекциях мы обратимся только к двум ПС: **Google** и **Яндекс** для иллюстрирования работы языка запросов.



Поиск нужной информации

- Третий этап является определяющим: от его реализации зависит, будет ли найденная информация пертинентной.
- На этом этапе пользователь работает с конечным результатом поиска – откликом ПС на запрос.



Советы по поиску в интернете



Необходимое замечание

- Советы по поиску в интернете взяты с сайта ПС Яндекс, поэтому все перечисленные советы **напрямую относятся к этой ПС.**
- В других ПС некоторые советы могут **не работать.**



Проверяйте орфографию

- Если поиск не нашел ни одного документа, то вы, возможно, допустили **орфографическую ошибку** в написании слова. Проверьте правильность написания.
- Если вы использовали при поиске несколько слов, то посмотрите на количество каждого из слов в найденных документах.
- **Какое-то из слов не встречается ни разу?** Скорее всего, его вы и написали неверно.



Используйте синонимы


- Если список найденных страниц слишком мал или не содержит полезных страниц, **попробуйте изменить слово**.
- Попробуйте задать для поиска **три-четыре слова-синонима** сразу.
- Для этого перечислите их через **вертикальную черту (|)**. Тогда будут найдены страницы, где встречается хотя бы одно из них.



Ищите больше, чем по одному слову

- Многие слова при поиске поодиночке дадут большое число **бессмысленных ссылок**.
- **Добавьте одно или два ключевых слова**, связанных с искомой темой. Например, «психология Юнга».
- Рекомендуем также **сужать область вашего вопроса**. Запрос «автомобиль Волга» выдаст более подходящие Вам документы, чем «легковые автомобили».

Распределение запросов по количеству слов





Не пишите большими буквами

- Начиная слово с большой буквы, вы **не найдете слов**, написанных с маленькой буквы, если это слово не первое в предложении.
- Поэтому не набирайте обычные слова с большой буквы, даже если с них начинается ваш вопрос Яндексy.
- Заглавные буквы в запросе рекомендуется использовать только в **названиях** и **именах собственных**. Например, *министр Иванов, телепередача Здоровье*.



Ищите без морфологии

- Вы можете заставить Яндекс **не учитывать** морфологические формы слов из запроса при поиске.
- Например, запрос **!иванов** найдет только страницы с упоминанием этой фамилии, а не города «Иваново».



Ищите похожие документы

- Если один из найденных документов ближе к искомой теме, чем остальные, нажмите на ссылку **«найти похожие документы»**.
- ПС проанализирует страницу и найдет документы, похожие на тот, что вы указали.




Используйте знаки «+» и «-»

- Чтобы исключить документы, где встречается определенное слово, поставьте перед ним **знак минуса**.
- И наоборот, чтобы определенное слово обязательно присутствовало в документе, поставьте перед ним **плюс**.
- Обратите внимание, что между словом и знаком плюс-минус **не должно быть пробела**.



Используйте язык запросов

- С помощью специальных операторов вы сможете сделать запрос **более точным**.
- Например, укажите, каких слов не должно быть в документе, или что два слова должны идти подряд одно за другим, а не просто встречаться в документе.
- О языке запросов мы поговорим подробнее на следующем занятии.



*Сохранение
информации
из интернета*



Сохранение web-страниц

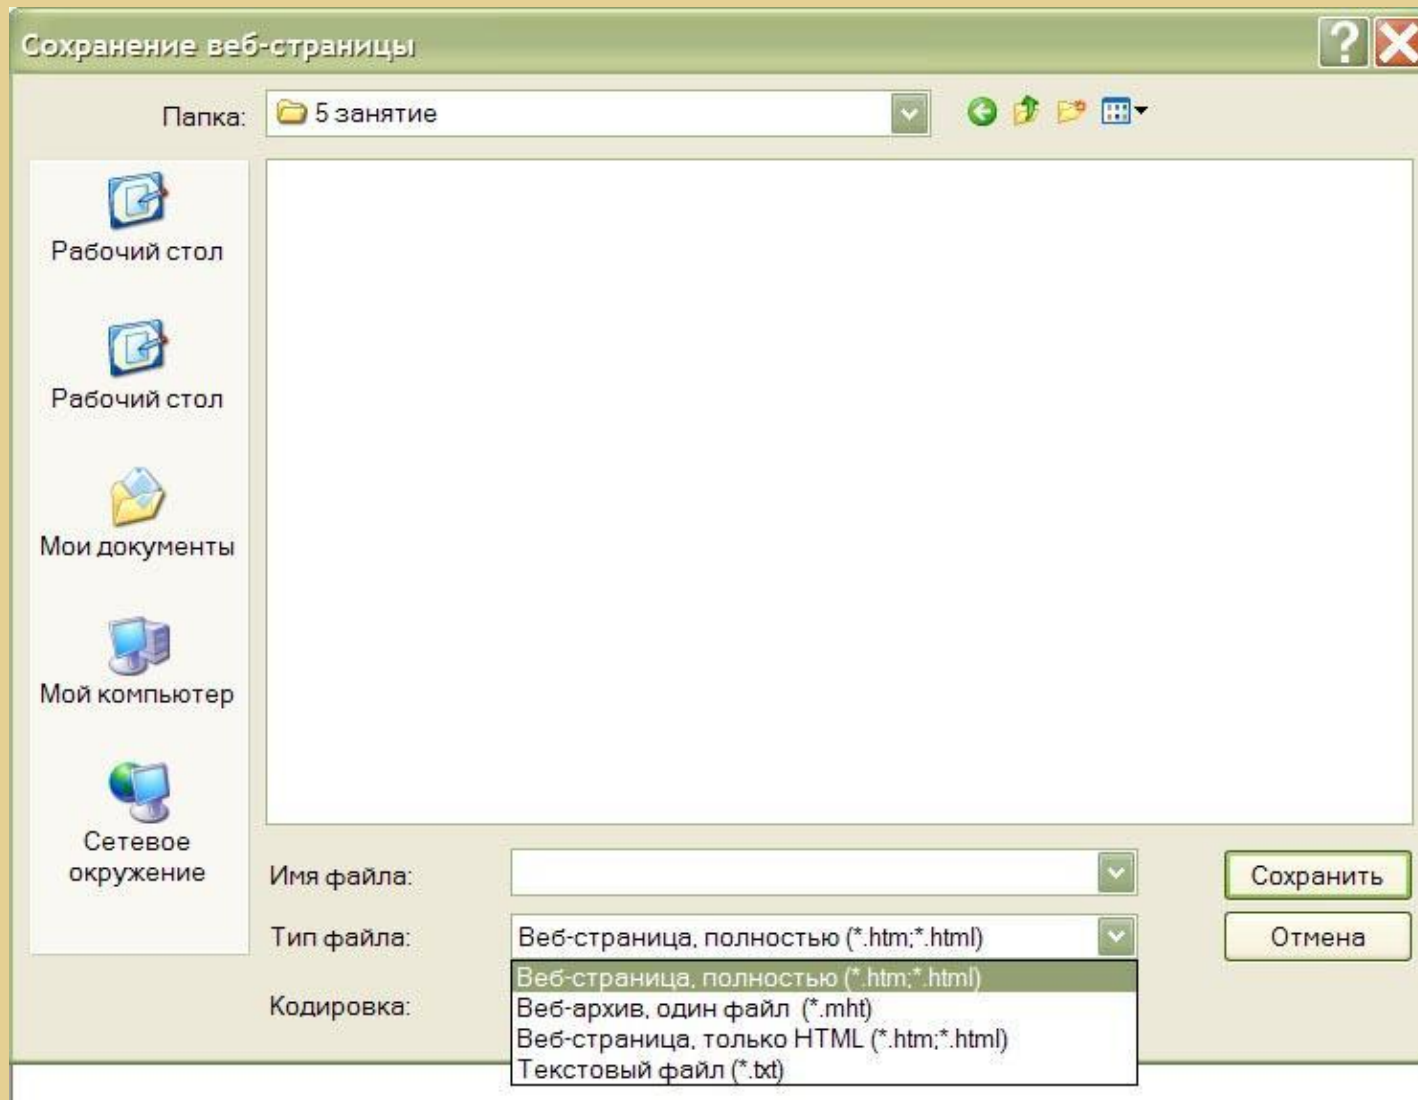
- Самая главная операция любого пользователя интернета – **сохранение найденной информации.**
- Итак, **сохранение документа с помощью меню броузера.**
- Имеют значение два обстоятельства:
 - тип броузера,
 - в каком виде вы хотите сохранить документ.



Сохранение web-страниц

- Microsoft Internet Explorer позволяет сохранить документ как:
 - web-страницу полностью (со всеми иллюстрациями, которые разместятся в отдельной папке, что довольно удобно);
 - web-архив (с включенными иллюстрациями);
 - web-страницу, один файл (без иллюстраций, только HTML);
 - текстовый файл (только текст документа).
- Вы можете также указать кодировку страницы.

Сохранение в Microsoft Internet Explorer






Сохранение web-страниц

- Opera позволяет сохранить документ как:
 - HTML-файлы (без иллюстраций, только HTML);
 - HTML-файлы с рисунками (со всеми иллюстрациями, которые разместятся в той же папке, что и документ);
 - текстовый файл (только текст документа).

Сохранение в Opera





Сохранение файлов других типов

- В случае сохранения **файлов других типов** (doc, ppt, pdf и т.д.) браузер автоматически начнет **«скачивание» файла** после Вашего **подтверждения**.
- Существуют и **специальные утилиты** для **«скачивания»** из интернета (ReGet).
- Они могут решать, например, такую проблему как **восстановление перекачки** после обрыва связи.



Совет по сохранению информации

- В случае, если Вы ищете информацию в разных документах, будет оптимально **использовать любой текстовый редактор** (MS Word, например) для копирования информации из web-страниц.
- **Принцип работы:** найденную информацию на web-странице Вы выделяете в броузере, копируете в буфер обмена, открываете текстовый редактор, вставляете из буфера текст.



Таким образом,

- Мы изучили устройство поисковой системы,
- разобрали теоретические подходы к поиску информации,
- рассмотрели советы по эффективному поиску в интернете,
- изучили способы сохранения информации из интернета.



Источники информации

- Гусев В.С. Google: эффективный поиск. Краткое руководство. – М.: «Вильямс», 2006.
- Ландэ Д.В. Поиск знаний в INTERNET. Профессиональная работа.: Пер. с англ. – М.: «Вильямс», 2005.
- Язык запросов. Как искать? Помощь Яндекса.
<http://www.yandex.ru/search/?id=481939>