# Интеллектуальные информационные системы

Лекция 3

# *Инструментальные средства создания гипертекстовых систем*

Благодаря широкому использованию ГТ в ИС практически любой инструментарий разработки ИС включает функции для построения ГТ. В частности, данные функции реализуются в средствах разработки электронной документации (например, Adobe Acrobat), авторских системах, редакторах презентаций, издательских системах, редакторах web-страниц и др.

Существует также специализированный инструментарий:

# Microsoft Windows Help (WinHelp) и HTML Help

- стандартные технологии построения и работы с гипертекстовыми справочниками для платформы Windows. Они позволяют формировать самые разнообразные ГТ:

- электронные руководства,
- справочники,
- энциклопедии,
- пособия и др.

Однако главное назначение данных технологий — реализация контекстно-зависимых гипертекстовых справочников по программным продуктам. Такие справочники являются неотъемлемым компонентом прикладных программных систем. По умолчанию они вызываются клавишей F1 или через меню «Справка». Информация, отображаемая в окне справочника после его вызова, зависит от текущего режима работы приложения, с которым он связан. Поэтому подобные справочники называются *контекстно-зависимыми*

# Создание гипертекстового справочника по программному продукту состоит из шести основных этапов.

1. **Определение структуры справочника и его разделов.**

Этот этап является наиболее сложным и трудно формализуемым. В рамках него специфицируются:

- назначение продукта, для которого создается справочник;
- категории пользователей продукта;
- рыночный сектор, на который ориентирован продукт;
- функции и характеристики продукта, представляемые в справочнике;
- основные разделы справочника и их примерное содержание;
- соглашения, фиксирующие стиль, дизайн и оформление справочника.

2. Подготовка текста и графических иллюстраций справочника. Определение гипертекстовых ссылок. Формирование файлов тем (ИСС) и графических файлов, включая задание контактных областей для гиперграфики.
3. Создание файла проекта справочника.

4. Компиляция исходных файлов тем, графических файлов и файла проекта с формированием файла справочника.
5. Программная реализация модуля приложения, обеспечивающего доступ к справочнику.
6. Тестирование и отладка справочника.

Гипертекст в формате WinHelp реализуется в виде файла с расширением HLP (help-файла). Представление и взаимодействие со справочником обеспечивает программа WINHELP.EXE, входящая в состав Windows. HLP-файл формируется на основе файлов с текстом в формате RTF с помощью специального компилятора. Для вызова справочника из приложения служит функция Windows API WinHelp().

Гипертекст в формате HTML Help реализуется в виде файла с расширением CHM. Представление и взаимодействие со справочником обеспечивают программные компоненты браузера Internet Explorer (начиная с версии 4.0). Для вызова справочника из приложения служит функция HTML Help API HtmlHelp().

# К достоинствам HTML Help относятся:

- мощные средства языка HTML, включая каскадные таблицы стилей;
- возможности использования компонентов ActiveX и скриптов;
- тесная интеграция с технологиями Internet;
- возможность создания составных гипертекстовых справочников, объединяемых во время выполнения.
- Информация в CHM-файле хранится в сжатом виде. Степень компрессии составляет примерно 8:1.

Гипертекст в формате HTML Help может быть разработан с помощью различных инструментальных средств. Наиболее популярными из них являются HTML Help Workshop фирмы Microsoft и KeyTools фирмы KeyWorks Software. Система Anet Help Tool российской фирмы Anet Soft позволяет создавать ГТ в формате как HTML Help, так и WinHelp.

# Инструментальная среда HyperRef

Предназначена для построения электронных гипертекстовых изданий большого объема. Разработана в МЭИ (ТУ).

HyperRef поддерживает следующие типы информационных объектов:

- текстовые экранные страницы,
- графические изображения,
- исполняемые модули.

# Инструментальная среда HyperRef

Объекты объединяются как в линейные последовательности, метафорой которых является глава или раздел книги, так и в гипертекстовую сеть. В визуальных объектах могут быть определены интерактивные элементы, используемые для организации гиперссылок.

HyperRef поддерживает типизацию гиперссылок и содержит средства навигации по ГТ с учетом ограничений, обусловленных типами ссылок.

# В состав HyperRef входят:

- диалоговый инструментарий автора (конструктор);
- пользовательская программа для работы с ГТ (исполнитель);
- набор утилит, позволяющих осуществлять поточный ввод информации, контролировать и восстанавливать целостность электронных гипертекстовых документов и т. д.

В HyperRef предусмотрены средства, присущие фактографическим и полнотекстовым БД: словари ключевых слов, оглавления, средства выполнения сложных запросов и автоматической индексации текстов.

**Автоматизированная система формирования и обработки гипертекстов (АСФОГ)**

создана в МЭСИ, предназначена для моделирования экономических объектов и процессов на основе представления информационного фонда ПрО в виде ГТ.

АСФОГ целесообразно использовать для моделирования слабоструктурированных ПрО, когда поиск текстовой информации в традиционных линейных и иерархических структурах неэффективен из-за их неадекватности реальной сетевой структуре информационных объектов, представляющих эти ПрО.

# Программное обеспечение АСФОГ реализовано в трех подсистемах

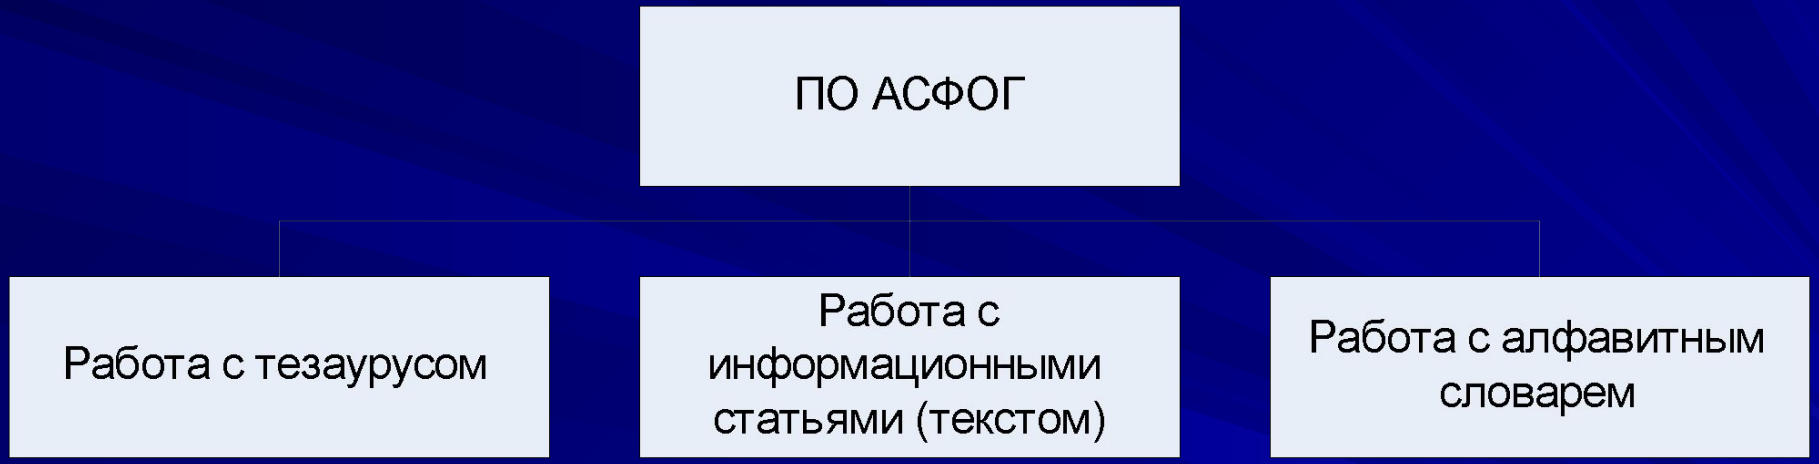

# Подсистема работы с тезаурусом

выполняет следующие функции:

- поиск в тезаурусе (поиск по связям с учетом их типов, контекстный поиск по связям);
- поддержка ускоренного просмотра;
- формирование отчетов;
- поддержка формирования и корректировки тезауруса.

# Подсистема работы с информационными статьями

- создание ИСС с помощью текстового редактора типа Word;
- коррекция ИСС;
- доступ к ИСС;
- формирование и печать отчетов по ИСС;
- импорт и экспорт файлов, содержащих ИСС.

Подсистема работы с алфавитным словарем решает следующие задачи:

- алфавитная сортировка (лексико-графическое упорядочение) заголовков ИСС;
- контекстный поиск ИСС по заголовку;
- поддержка ускоренного просмотра словаря;
- печать информации из словаря.

# *Гипертекстовые информационно-поисковые системы*

Гипертекстовая информационная технология используется при организации больших массивов текстовых документов и реализации методов поиска информации в них.

***Информационный поиск*** — совокупность операций, методов и процедур, направленных на отбор данных, хранящихся в ИС и соответствующих заданным условиям.

# Информационно-поисковые системы (ИПС) подразделяются на три класса:

- документальные;
- фактографические;
- гипертекстовые (ГИПС).

# Документальные ИПС

Документальные ИПС хранят и выдают сведения о документах, основное содержимое которых представлено в виде связанного текста на естественном языке (ЕЯ). Признаки документа, отражающие его содержание в ИПС, называют ***поисковым образом***, а признаки запроса к ИПС — ***поисковым предписанием.***

Процедура перевода документа и запроса в форму представления, принятую в ИПС, называется ***индексированием***. При сопоставлении поискового образа и поискового предписания используется тот или иной ***критерий смыслового соответствия (релевантности).***

Первые ИПС были предназначены для поиска книг в библиотеках и получили название библиографических. Позже их стали применять и для поиска документов в больших хранилищах и стали называть *документальными*

Основным объектом информационного фонда документальной ИПС является ***аннотация (реферат)*** *и* ***библиографическое описание документа*** (книги, события, предмета). Реферат (аннотация) выражается на ЕЯ и отражает основные характеристики документа, представляющие интерес для пользователей. Предполагается, что в подобном описании можно выделить ряд слов и словосочетаний, число которых значительно меньше общего числа слов в описании. В то же время выделенная информация достаточно точно характеризует описание. Такие слова и словосочетания называются ***ключевыми словами*** *или* ***дескрипторами****.*

Запрос к документальной ИПС формулируется в виде перечня дескрипторов, которые по мнению пользователя характеризуют искомый документ.

При вводе в ИПС нового объекта (реферата) его дескрипторы автоматически включаются в словарь дескрипторов. Каждому дескриптору присваивается номер, называемый индексом дескриптора. Совокупность индексов, соответствующих полному набору дескрипторов реферата, составляет его поисковый образ. Новый поисковый образ снабжается уникальным идентификатором (регистрируется) и включается в массив поисковых образов. Тем же идентификатором помечается новый реферат, заносимый в массив рефератов.

# Организация поиска в дескрипторной ИПС

Запрос, сформулированный на ЕЯ, подвергается анализу, в рамках которого в нем выделяются дескрипторы, входящие в словарь дескрипторов. Их совокупность образует поисковое предписание, соответствующее запросу. Оно сопоставляется с поисковыми образами, в результате чего определяется их релевантность. Если поисковый образ и предписание релевантны, то из поискового образа извлекается идентификатор реферата, выдаваемого пользователю. Ответом на запрос является множество рефератов, соответствующих отобранным в процессе поиска идентификаторам.

В целях ускорения поиска для каждого дескриптора в словаре дескрипторов указывается список идентификаторов рефератов, в которых он встречается. Такая информационная структура ИПС называется *индексом*.

С помощью дескрипторов можно лишь приблизительно отразить смысл документов. Это же относится к переводу запросов в поисковые предписания. Документальная ИПС может выдать рефераты, не относящиеся к поисковому запросу, или не найти рефераты, которые соответствуют ему.

Документальный поиск относится к числу сложных информационных процессов, поскольку он связан с проблемой оценивания смыслового соответствия документа и запроса. Из-за субъективности и неоднозначности подобного оценивания этот вид поиска в принципе не может быть исчерпывающе точным и полным, в нем всегда будет присутствовать элемент нечеткости.

Развитием поиска по дескрипторам является полнотекстовый поиск, реализуемый, например, в поисковых машинах Internet. В системах, использующих данный вид поиска, индекс формируется на основе всех слов и словосочетаний, содержащихся в документах, за исключением служебных неинформативных слов (союзов, предлогов, местоимений и т. п.). При индексировании с помощью словарей и средств морфологического анализа слова приводятся к базовой грамматической форме (именительный падеж, единственное число и т. д.).

# Фактографические ИПС

В фактографических ИПС хранятся не документы, а собственно сведения (факты) об объектах ПрО. Подобные ИПС реализуются, в частности, на основе реляционных БД. С точки зрения обеспечения релевантности результатов поиска (выборки данных) запросу фактографический поиск в отличие от документального является точным и полным.

# Гипертекстовые ИПС

В гипертекстовых ИПС кроме содержимого документов отражается их семантическая структура. Поэтому по глубине формализации ГИПС занимают промежуточное положение между документальными и фактографическими ИПС.

# Поиск по метаданным

Одно из направлений развития технологии документальных ИПС связано со структуризацией и унификацией сведений о документах. Такие сведения по отношению к исходным документам играют роль метаданных. Примером метаданных служит библиографическое описание, содержащее информацию об авторах документа, дате его создания, объеме, форме представления и т. д. Ключевые слова также относят к метаданным.

Поиск по метаданным сближает технологии документальных и фактографических ИПС. С одной стороны, метаданные представляют документы. С другой стороны, некоторые элементы метаданных допускают четкое определение релевантности запроса и записи в БД (экземпляра метаданных, ассоциируемых с конкретным документом), что характерно для фактографических ИПС.

В настоящее время хранилища метаданных обычно реализуются на основе реляционных и XML-ориентированных БД и используют механизмы поиска, воплощаемые в соответствующих СУБД.

# Классификация и характеристики методов информационного поиска

Введем следующие обозначения:

$D$ – множество документов в информационном хранилище

$d_i \in D$ – $i$ – тый документ

$D_j \in D$ – подмножество документов

В данном контексте под документом будем понимать как собственно текстовый или гипертекстовый документ, так и отдельную запись в БД.

Зададим на $D$ оценку смысловой близости пары документов $r(d_i, d_j) \geq 0$. При $r=0$ документы $d_i$ и $d_j$ эквивалентны по смыслу. Для семантически несопоставимых документов не $r$ определена.

Введем оценки ряда важных свойств документов: $S=(S_1, S_2, \ldots, S_k)$, $k>0$. Пусть оценка каждого свойства $S_j$ выражается действительным числом, принадлежащим некоторому интервалу. Для определенности примем, что чем больше значение $S$, тем важнее для пользователя документ.

Поисковый запрос может рассматриваться как виртуальный документ *z*. В идеальном случае *(r(z,$d_j$)=0)* ему точно соответствует документ $d_j$.

$D_j = \varnothing$

Используя введенные обозначения, определим следующие виды поиска:

1. Найти $\left(D_j \subseteq D\right) \middle| r\left(z, d_i \in D_j\right) \to \min$

Если $D_j = \varnothing$, то в *D* нет докуметов, релевантных запросу. При $|D_j|=1$ есть единственный подходящий документ. Если $|D_j|>1$, то таких документов несколько

2. Найти $\left(D_j \subseteq D\right) \middle| r\left(z, d_i \in D_j\right) \le \Delta$, где $\Delta$ - оценка наибольшего допустимого расхождения смыслов запроса и искомых документов.

3. Найти $\left(D_j \subseteq D\right) \middle| S_j\left(d_i \in D_j\right) \to \max$. Результатом поиска служит подмножество документов, которым приписана наибольшая оценка важности *j*-го свойства. Обобщением этого варианта является векторный поиск, учитывающий оценки нескольких свойств.

4. Комбинированный поиск: найти

$$\left(D_j \subseteq D\right) \middle| r\left(z, d_j \in D_j\right) \le \Delta \;\&\; S_j\left(d_j \in D_j\right) \to \max$$

Интеллектуальные возможности ИПС в части функций информационного поиска обусловлены способами задания и вычисления *r* и *S*.

Эффективность информационного поиска документов, обеспечиваемая ИПС, оценивается по информационной полноте и информационному шуму. Названные показатели выражаются коэффициентами полноты $k_i$ и шума $k_ø$ соответственно. Коэффициенты $k_i$ и $k_ø$ принимают значения в интервале от 0 до 1. В некоторых источниках эти коэффициенты выражают в процентах.

Пусть ИПС предъявлен *i*-й запрос. Информационно-поисковая система содержит множество документов $D_i$ релевантных этому запросу. В результате поиска получено множество $D_I^0$, Возможны следующие варианты:

1. $D_i^0 = D_i$. Идеальный вариант: полнота максимальна ($k_r = 1$) а шум нулевой ($k_g = 0$).
2. $D_i^0 \subset D_i$. Имеет место неполнота ($0 \le k_r < 1$), а шум отсутствует ($k_g = 0$).
3. $D_i^0 \supset D_i$. Неполнота исключается ($k_r = 1$), но есть шум ($0 \le k_g < 1$).
4. $D_i^0 \cap D_i = \varnothing \;\&\; D_i^0 \neq \varnothing \;\&\; D_i \neq \varnothing$. Худший вариант: нулевая полнота (ни один релевантный документ не найден: $k_r = 0$) и максимальный шум (все, что выделено, не соответствует запросу: $k_g = 1$).
5. $D_i^0 \cap D_i \neq \varnothing \;\&\; D_i^0 \not\subset D_i \;\&\; D_i \not\subset D_i^0 \;\&\; D_i^0 \neq D_i$. Имеют место и неполнота ($0 \le k_r < 1$), и шум ($0 \le k_g < 1$).

# Определим коэффициенты полноты и шума:

$$k_т = \lim_{k \to m} \frac{1}{k} \sum_{i=1}^{k} \frac{\left| D_i \cap D_i^0 \right|}{\left| D_i \right|}, \quad k_ш = \lim_{k \to m} \frac{1}{k} \sum_{i=1}^{k} \frac{\left| D_i \setminus D_i^0 \right|}{\left| D_i \right|},$$

где $m$ - достаточно большое число, чтобы по теореме о больших числах обеспечить требуемую достоверность результата эксперимента по определению $k_т$ и $k_ш$.

# Смысл коэффициентов полноты и шума

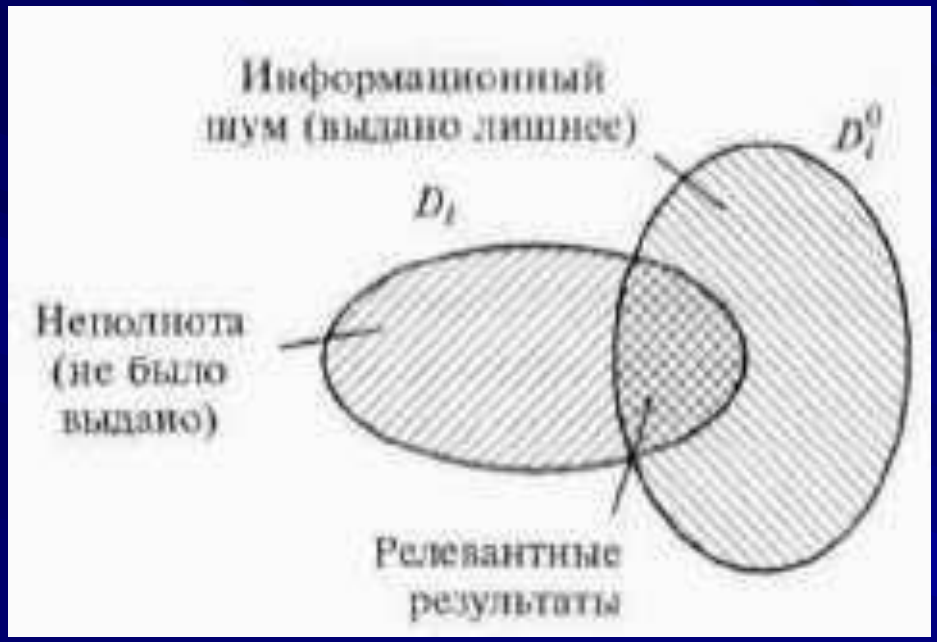


Успешность поиска формально определяется степенью совпадения множеств $D_i$ и $D_i^0$.

# Сравнение документальных, фактографических и гипертекстовых ИПС по ряду показателей

| Характеристики ИПС | Виды ИПС | | |
|---|---|---|---|
| | Документальные | Фактографические | Гипертекстовые |
| Полнота и шум | $k_{i\ max}$=0,5<br>$k_{\varnothing\ max}$=0 | $k_{i\ max}$=1<br>$k_{\varnothing\ max}$=0 | $k_{i\ max}$=0,9…1,0<br>$k_{\varnothing\ max}$=0,1…0,2 |
| Систематизирующая информация | Поисковые образы документов, метаданные | Значения атрибутов объектов ПрО | Гипертекстовое представление документов, метаданные |
| Тип поискового аппарата | Информационно-поисковые языки с развитой грамматикой | Языки реляционного типа | Гипертекстовый тезаурус |
| Трудоемкость подготовки информационного массива | Требуется специальная лингвистическая подготовка сотрудника | Требуется высокая квалификация сотрудника | Относительно несложная подготовка по типам семантических связей |
| Структуры данных | Прямые и инверсные списки | Иерархические или реляционные структуры | Семантическая сеть: вершины – понятия, ребра – отношения |
| Математический характер критериев поиска | Логические и алгебраические выражения | Логические и алгебраические выражения | Семантические признаки |
| Тип собственного языка системы | Специальные информационные языки (например, Сетка-5) | Специальные языки (SQL, QBE) | ОЕЯ ПрО |

# Системы контекстной помощи

Системы контекстной помощи можно рассматривать как частный случай интеллектуальных гипертекстовых и естественно-языковых систем. В отличие от обычных систем помощи, навязывающих пользователю схему поиска требуемой информации, в системах контекстной помощи пользователь описывает проблему (ситуацию), а система с помощью дополнительного диалога ее конкретизирует и сама выполняет поиск относящихся к ситуации рекомендаций. Такие системы относятся к классу систем распространения знаний (Knowledge Publishing) и создаются как приложение к системам документации (например, технической документации по эксплуатации товаров).