

Открытые стандарты обработки документов. SGML и XML

*Борис Тоботрас,
«Инфосистемы Джет»*

Почему SGML?

Проблемы с обработкой документов:

- множество различных закрытых *несовместимых* форматов
- постоянная смена форматов и приложений
- трудности автоматической генерации и обработки документов
- непереносимость документов

Что такое SGML?

- международный стандарт разметки документов (ISO 8879:1986)
- метаязык для создания языков разметки - *приложений SGML* (например, HTML)
- документы хранятся в текстовом виде
- документы состоят из текста и элементов разметки
- структура документа строго определена

Что можно в SGML?

- один источник - много выходных форматов
- Web, связанные документы
- управление документами, версии, контекстный поиск
- управление данными

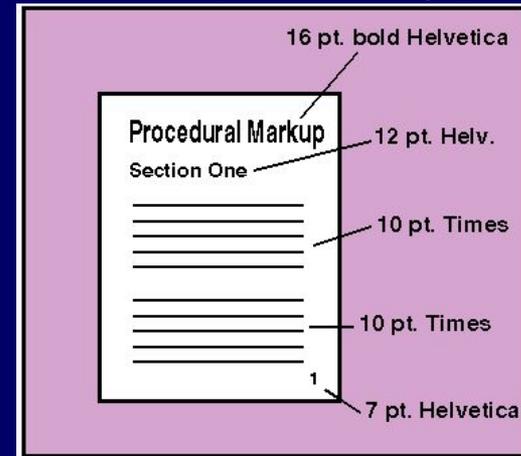
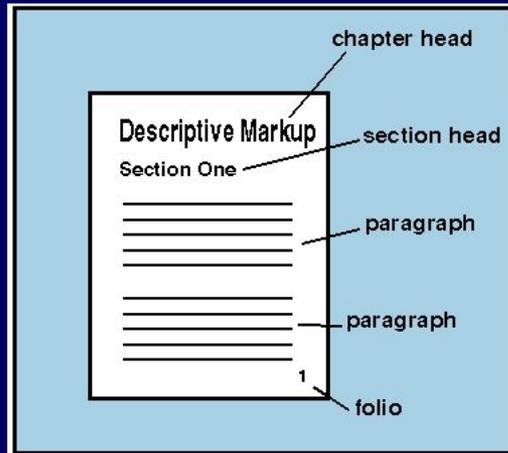
В чем суть SGML?

Отличия SGML

- разделение информации и представления
- типизированные документы
- выявление структуры информации
- управление данными
- связывание документов

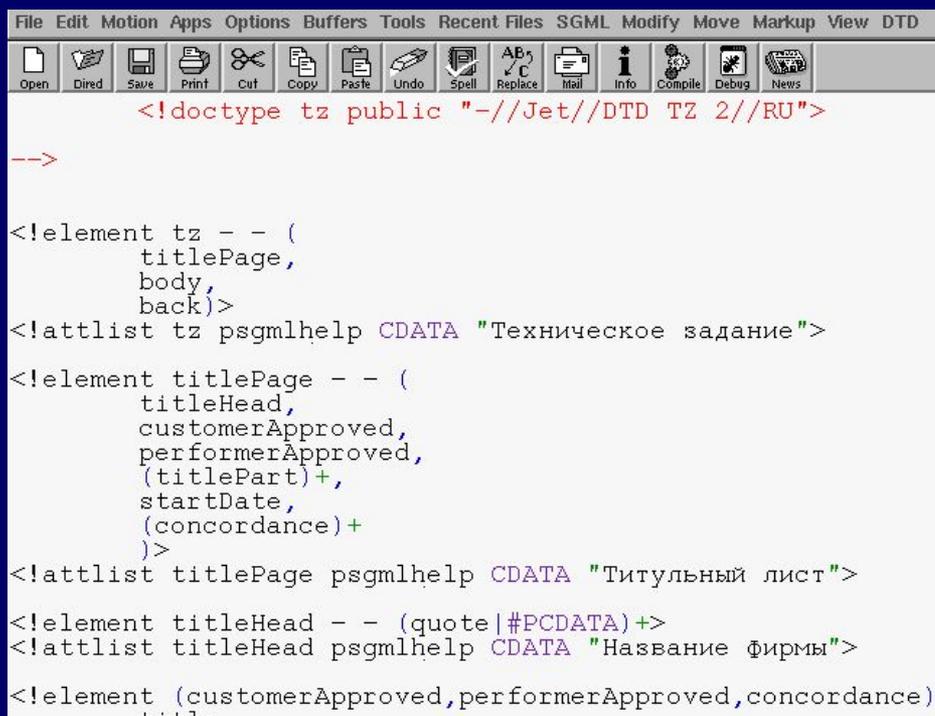
Информация и представление

- описательная разметка вместо процедурной



- жесткая структура документа
- разные способы обработки документа
- СТИЛИ

Типизированные документы

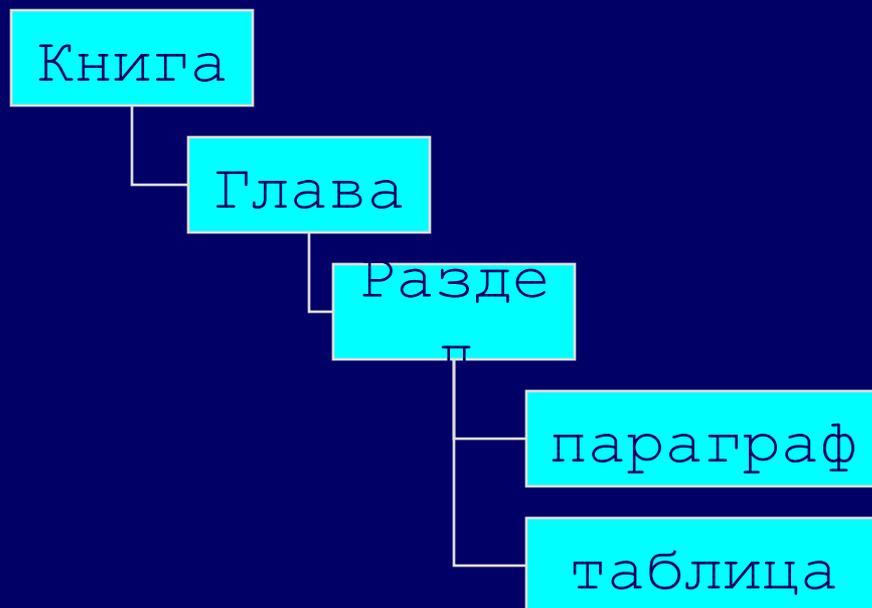


```
File Edit Motion Apps Options Buffers Tools Recent Files SGML Modify Move Markup View DTD
Open Dired Save Print Cut Copy Paste Undo Spell Replace Mail Info Compile Debug News
<!doctype tz public "-//Jet//DTD TZ 2//RU">
-->
<!element tz -- (
  titlePage,
  body,
  back)>
<!attlist tz psgmlhelp CDATA "Техническое задание">
<!element titlePage -- (
  titleHead,
  customerApproved,
  performerApproved,
  (titlePart)+,
  startDate,
  (concordance)+
)>
<!attlist titlePage psgmlhelp CDATA "Титульный лист">
<!element titleHead -- (quote|#PCDATA)+>
<!attlist titleHead psgmlhelp CDATA "Название фирмы">
<!element (customerApproved,performerApproved,concordance)
  title
```

- понятие DTD
- анализаторы
- какие бывают DTD
 - универсальные
 - специализированные
- как сделать свой DTD?
 - элементы и их структура
 - атрибуты

Структура информации

- структурные элементы
- обработка текста в контексте структуры
- Пример:



Управление данными

- СМЫСЛОВЫЕ ВЫДЕЛЕНИЯ
- обработка текста в контексте содержания
- Пример:



Связывание документов

- гарантия целостности
- двусторонние связи
- СВЯЗИ «ОДИН-КО-МНОГИМ» И «МНОГИЕ-КО-МНОГИМ»
- связи с произвольными точками документа
- Пример:
 - «ссылка на 3-ю главу 4-й части Руководства Администратора»

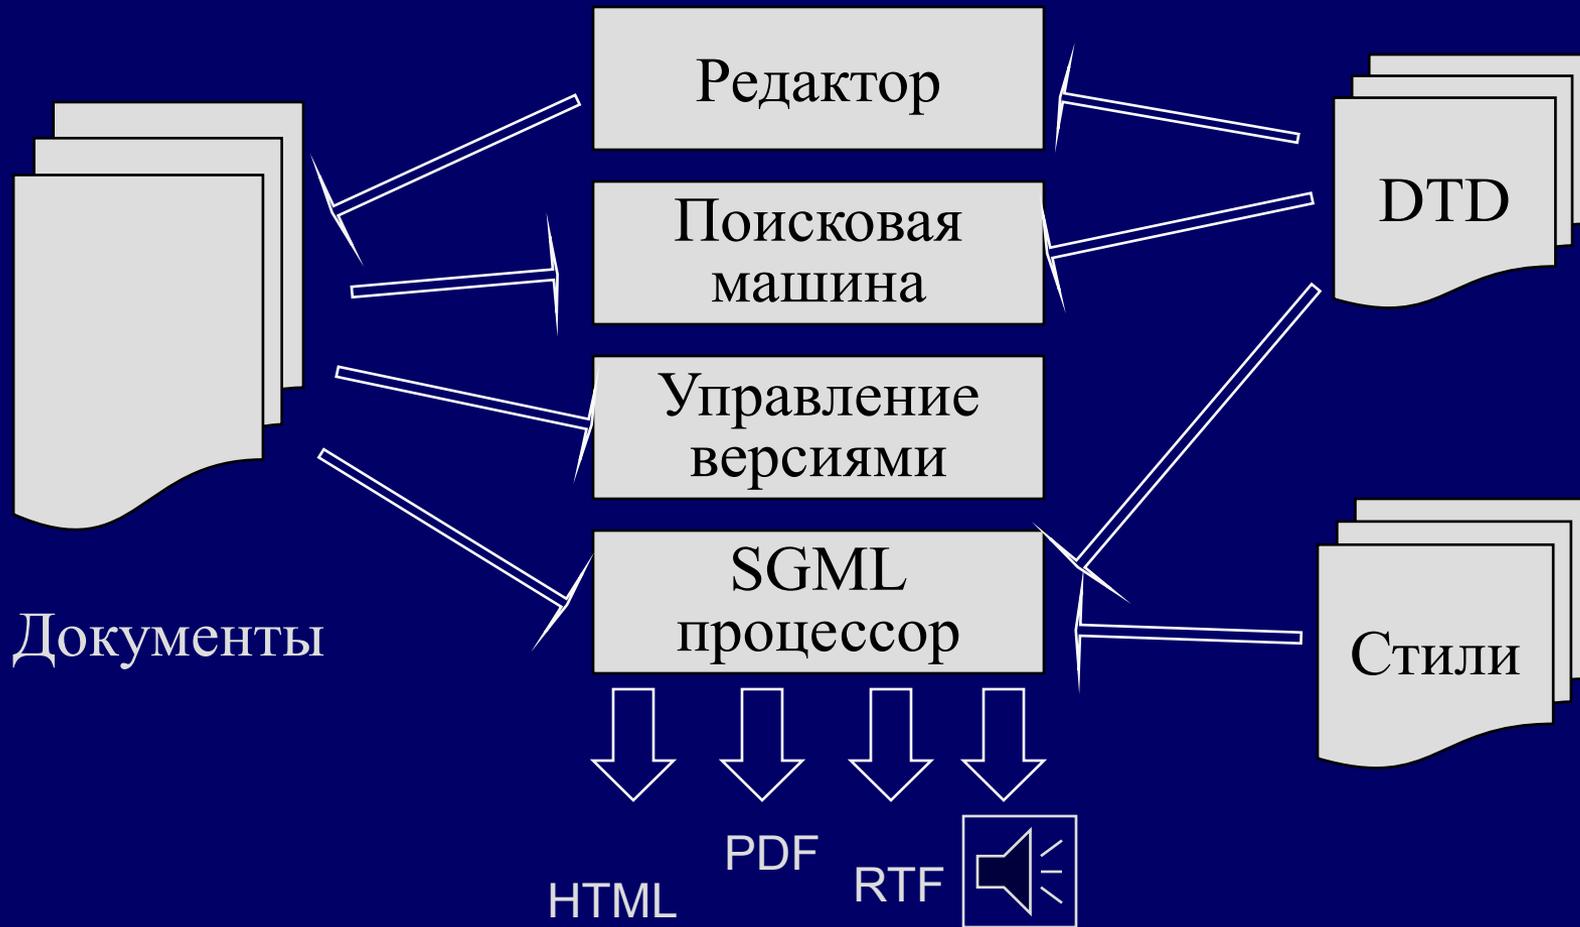
Преимущества SGML

- Продуктивность
- Единая стилистика
- Повторное использование
- Долговечность информации
- Разделяемость
- Мобильность
- Гибкость

SGML и другие

- HTML
 - уклон в сторону представления
 - размытость стандарта
 - нет возможностей расширения
- MS Word
 - закрытый
 - слабые средства автоматизации
 - нет смысловой и структурной разметки
- TeX
 - сложный, низкоуровневый
 - плохо экспортируется в Word

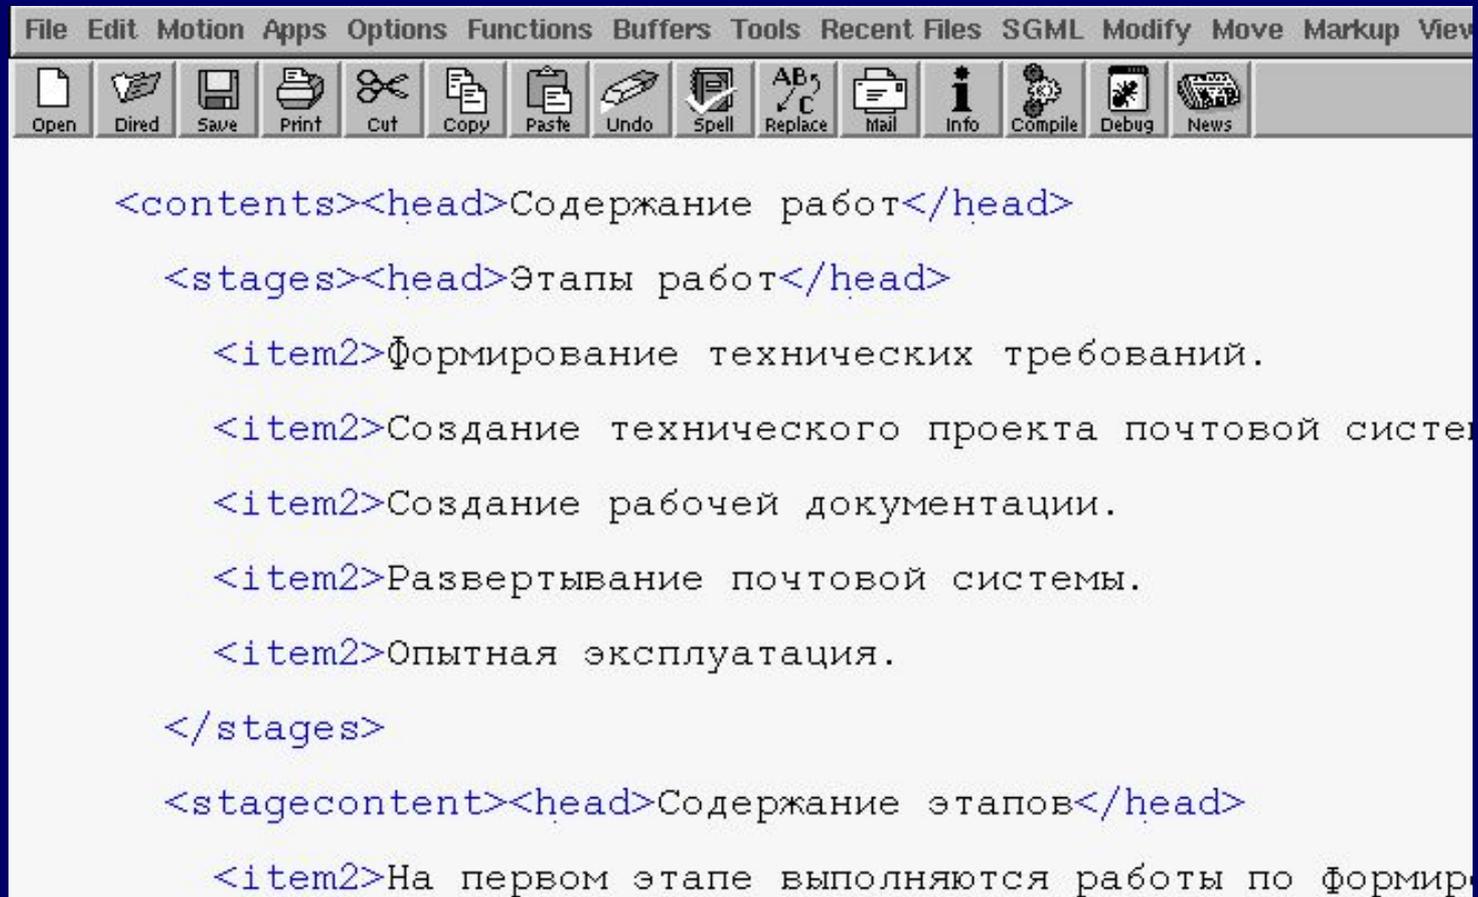
Как это делается



Как это делается

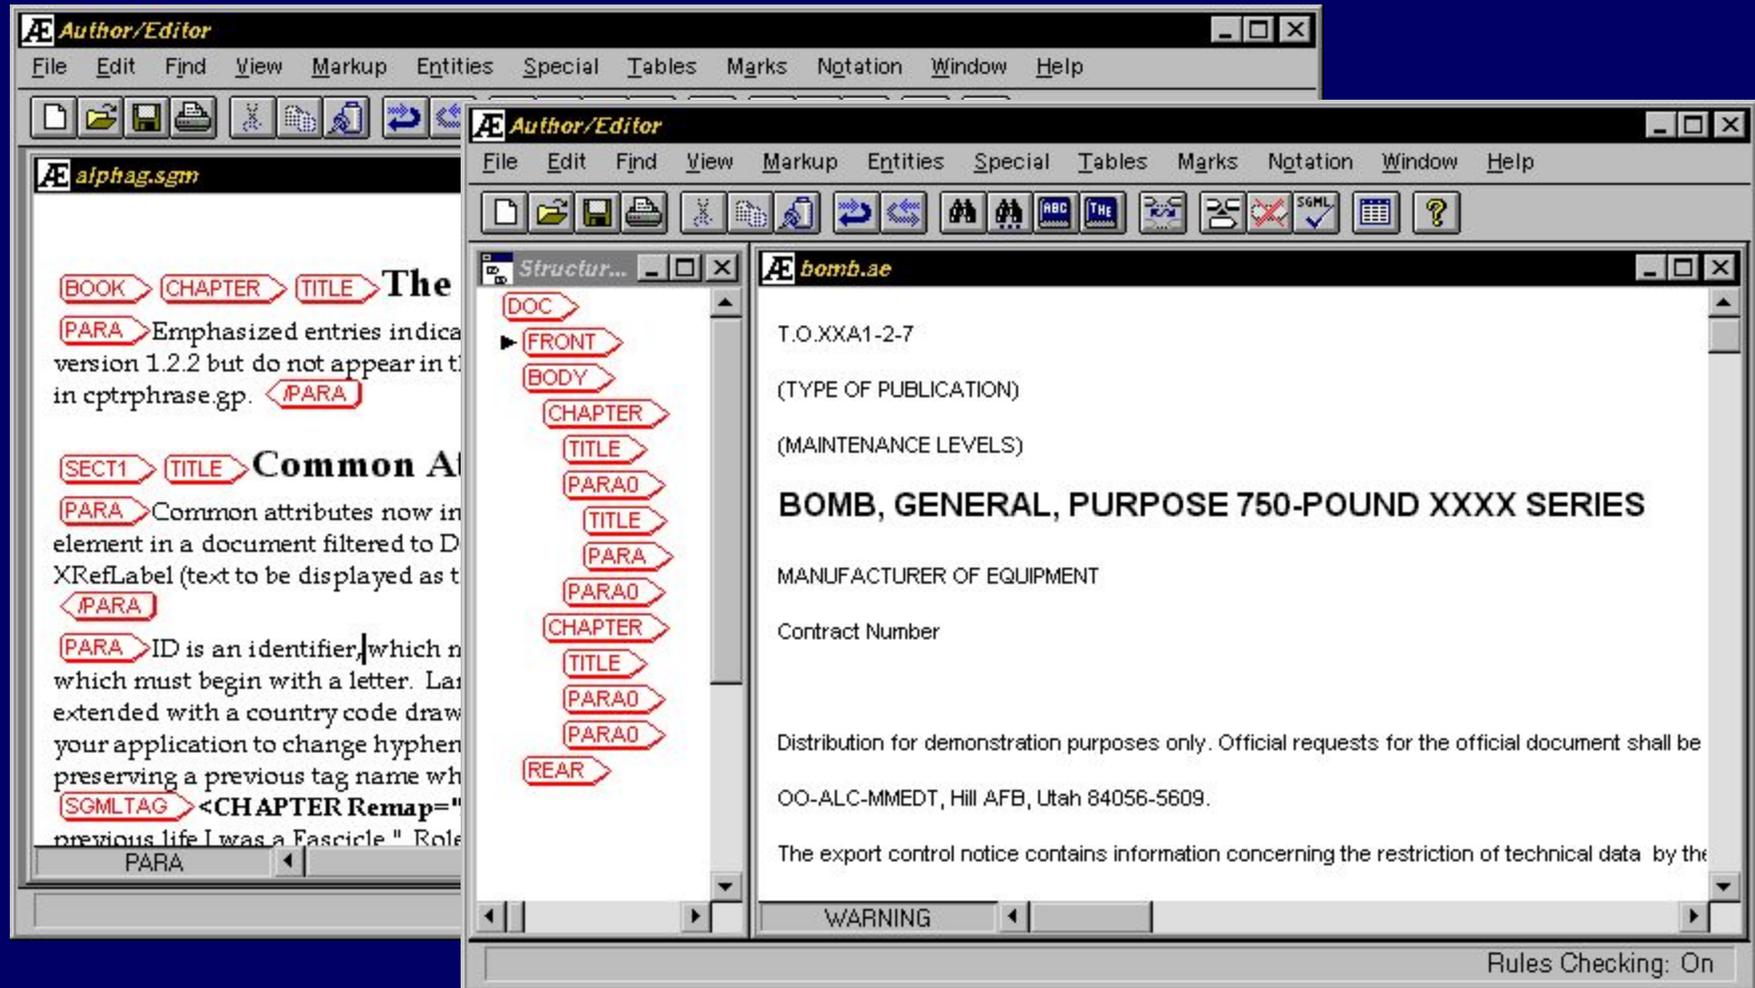
- SGML-редакторы
 - ArborText ADEPT*Editor, SoftQuad Author/Editor, Xemacs+psgml, Corel WordPerfect/SGML
- SGML-процессоры
 - SP, CoST, Jade, OmniMark, Balise,...
- Стили
 - DSSSL (Jade), XSL, CSS,...
- Выходные форматы
 - HTML, RTF, TeX, PostScript, PDF,...

Xemacs



```
<contents><head>Содержание работ</head>
  <stages><head>Этапы работ</head>
    <item2>Формирование технических требований.
    <item2>Создание технического проекта почтовой системы.
    <item2>Создание рабочей документации.
    <item2>Развертывание почтовой системы.
    <item2>Опытная эксплуатация.
  </stages>
  <stagecontent><head>Содержание этапов</head>
    <item2>На первом этапе выполняются работы по формированию
```

Author/Editor



Контроль версий

- Текстовые файлы
- CVS/RCS
- diff
- Web-интерфейс

Групповая работа над документами

- Внешние объекты (документы, рисунки...)
- Параллельная работа
- Библиотека иллюстраций
- Пакетная обработка (сборка документа)

Поиск в документах

- Текстовые файлы
- Полнотекстовый поиск
- Поиск в контексте (структурном и смысловом)
- glimpse, CGI, Web

Генерация Web-сервера

- Общее дерево сервера в SGML
- Мастер-документ
- Взаимные ссылки
- Средства верификации
- Единый стиль

XML

- SGML, ориентированный на Web
- Упрощенный синтаксис
- Не обязательно наличие DTD
- Простые анализаторы

XML vs. HTML

- Автоматизация формирования страниц
- Возможность экспорта с WWW
- Точность поиска
- Неограниченное количество элементов
 - <FAQ>
 - <Q>Что такое XML?</Q>
 - <A>eXtensible Markup Language
 - </FAQ>
- XSL и XLL - дополнение к XML

Инфосистемы Джет

Тел. 973-48-57, 973-48-58
info@jet.msk.su

Борис Тоботрас, tobotras@jet.msk.su