РОССИЙСКИЙ НАУЧНО-ОБРАЗОВАТЕЛЬНЫЙ ЦЕНТР ПО ЛИНГВИСТИКЕ ИМ. И.А.БОДУЭНА ДЕ КУРТЕНЭ

МГУ им. М.В.Ломоносова
Научно-исследовательский вычислительный центр

Казанский государственный университет им. В.И.Ульянова- Ленина

Автоматизированное индексирование описаний музейных предметов на базе русскоязычной версии Тезауруса по архитектуре и искусству (Тезауруса AAT)

Добров Б.В. , Лукашевич Н.В., Соловьев В.Д.

louk@mail.cir.ru

Доступ к цифровым ресурсам по культурному наследию

- **Объекты нетекстовой природы**
  - **Текстовые описания**
  - **Поиск по изображениям**
- **1-5% музейных экспонатов выставлено в экспозициях**
- **Лингвистические ресурсы для концептуального индексирования**
  - **Тезаурусы**
  - **Онтологии**

Тезаурус по архитектуре и искусству (тезаурус AAT)

- **Объем: 30 тысяч дескрипторов;130 тысяч англоязычных терминов**
- **Терминология по искусству, архитектуре, материальной культуре, архивным материалам с античности до наших дней.**
- **Наиболее полное покрытие: искусство Западной Европы и Америки**
- **Специфика искусства народов России представлена недостаточно**
- **Но перечислено множество общезначимых сущностей: материалов, объектов материальной культуры и искусства**

Адаптация Тезауруса AAT для описания культуры народов России

- **Перевод на русский язык**
- **Дополнение русскоязычными синонимами**
  - **Общезначимый русский язык (ручка – рукоятка – черенок)**
  - **Музейная терминология**
- **Дополнение специальной терминологией – отражение специфики культуры России**
- **Современные тенденции в развитии ресурсов:**
  - **Сбор текстовых коллекций (корпусов – каталоги, описания музейных предметов)**
  - **Автоматизированное извлечение терминов по текстам**

Информационная система «Культурное наследие РОССИИ»

- **Научно-образовательный центр по лингвистике при Казанском государственном университете**
- **НИВЦ МГУ- опыт:**
  - **Автоматизированная разработка терминологических ресурсов по текстовым коллекциям**
  - **Создание тезаурусов и онтологий для автоматического концептуального индексирования**
  - **Тезаурус русского языка РуТез – 49 тысяч понятий, 135 тысяч русскоязычных слов, выражений, терминов**
  - **Разработка информационных систем на основе технологий концептуального поиска**

Система автоматизированного индексирования на базе тезауруса AAT

- **Получена лицензия от фонда Гетти на некоммерческое использование тезауруса AAT**
- **Перевод фасетов AAT: Материалы и объекты**
- **Переведено 10 тысяч дескрипторов**
- **Ссылка на понятие тезауруса РуТез, если есть – известные общезначимые русскоязычные синонимы, дополнительные отношения**
- **Экспериментальная загрузка двуязычного ресурса в тезаурусную оболочку: исходный дескриптор – англоязычные синонимы, русскоязычный дескриптор, дополнение синонимами из Тезауруса РуТез**
- **Экспериментальная обработка реальной коллекции описаний музейных предметов**

Этапы работы системы автоматизированного индексирования

- **Графематический анализ текста– разбиение текста на значимые элементы: слова, знаки препинания, числа и т.п.**
- **Морфологический анализ текста – приведение слов текста к словарной форме**
- **Терминологический анализ текста – сопоставление слов текста с терминами тезауруса**
- **Разрешение неоднозначности – *ручка: ручка чашки, перьевая ручка***
- **Результат: индекс по дескрипторам тезауруса – концептуальный индекс – не зависит от исходного языка документа**

Фрагмент файла перевода фасета «Материалы»

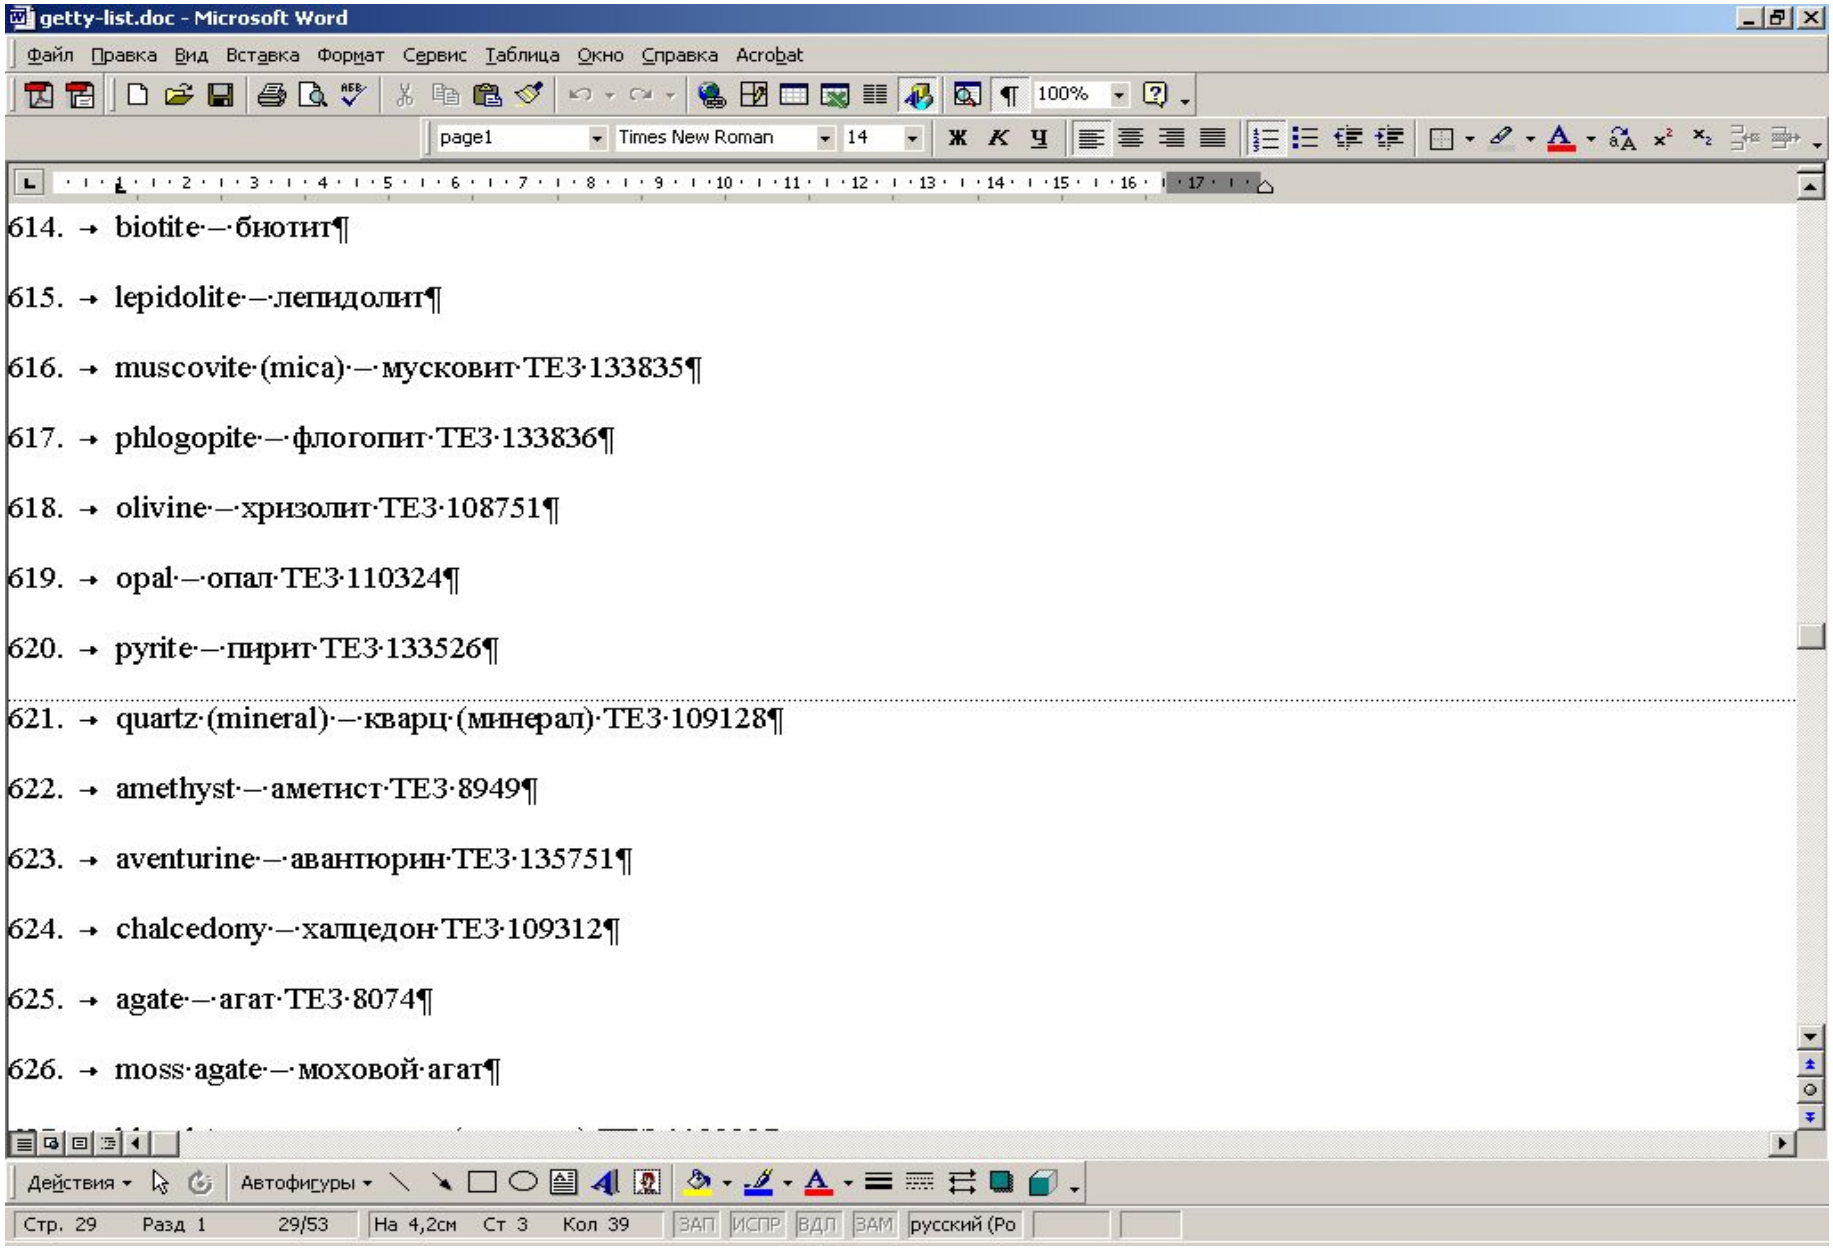

Экран программной оболочки ведения тезауруса

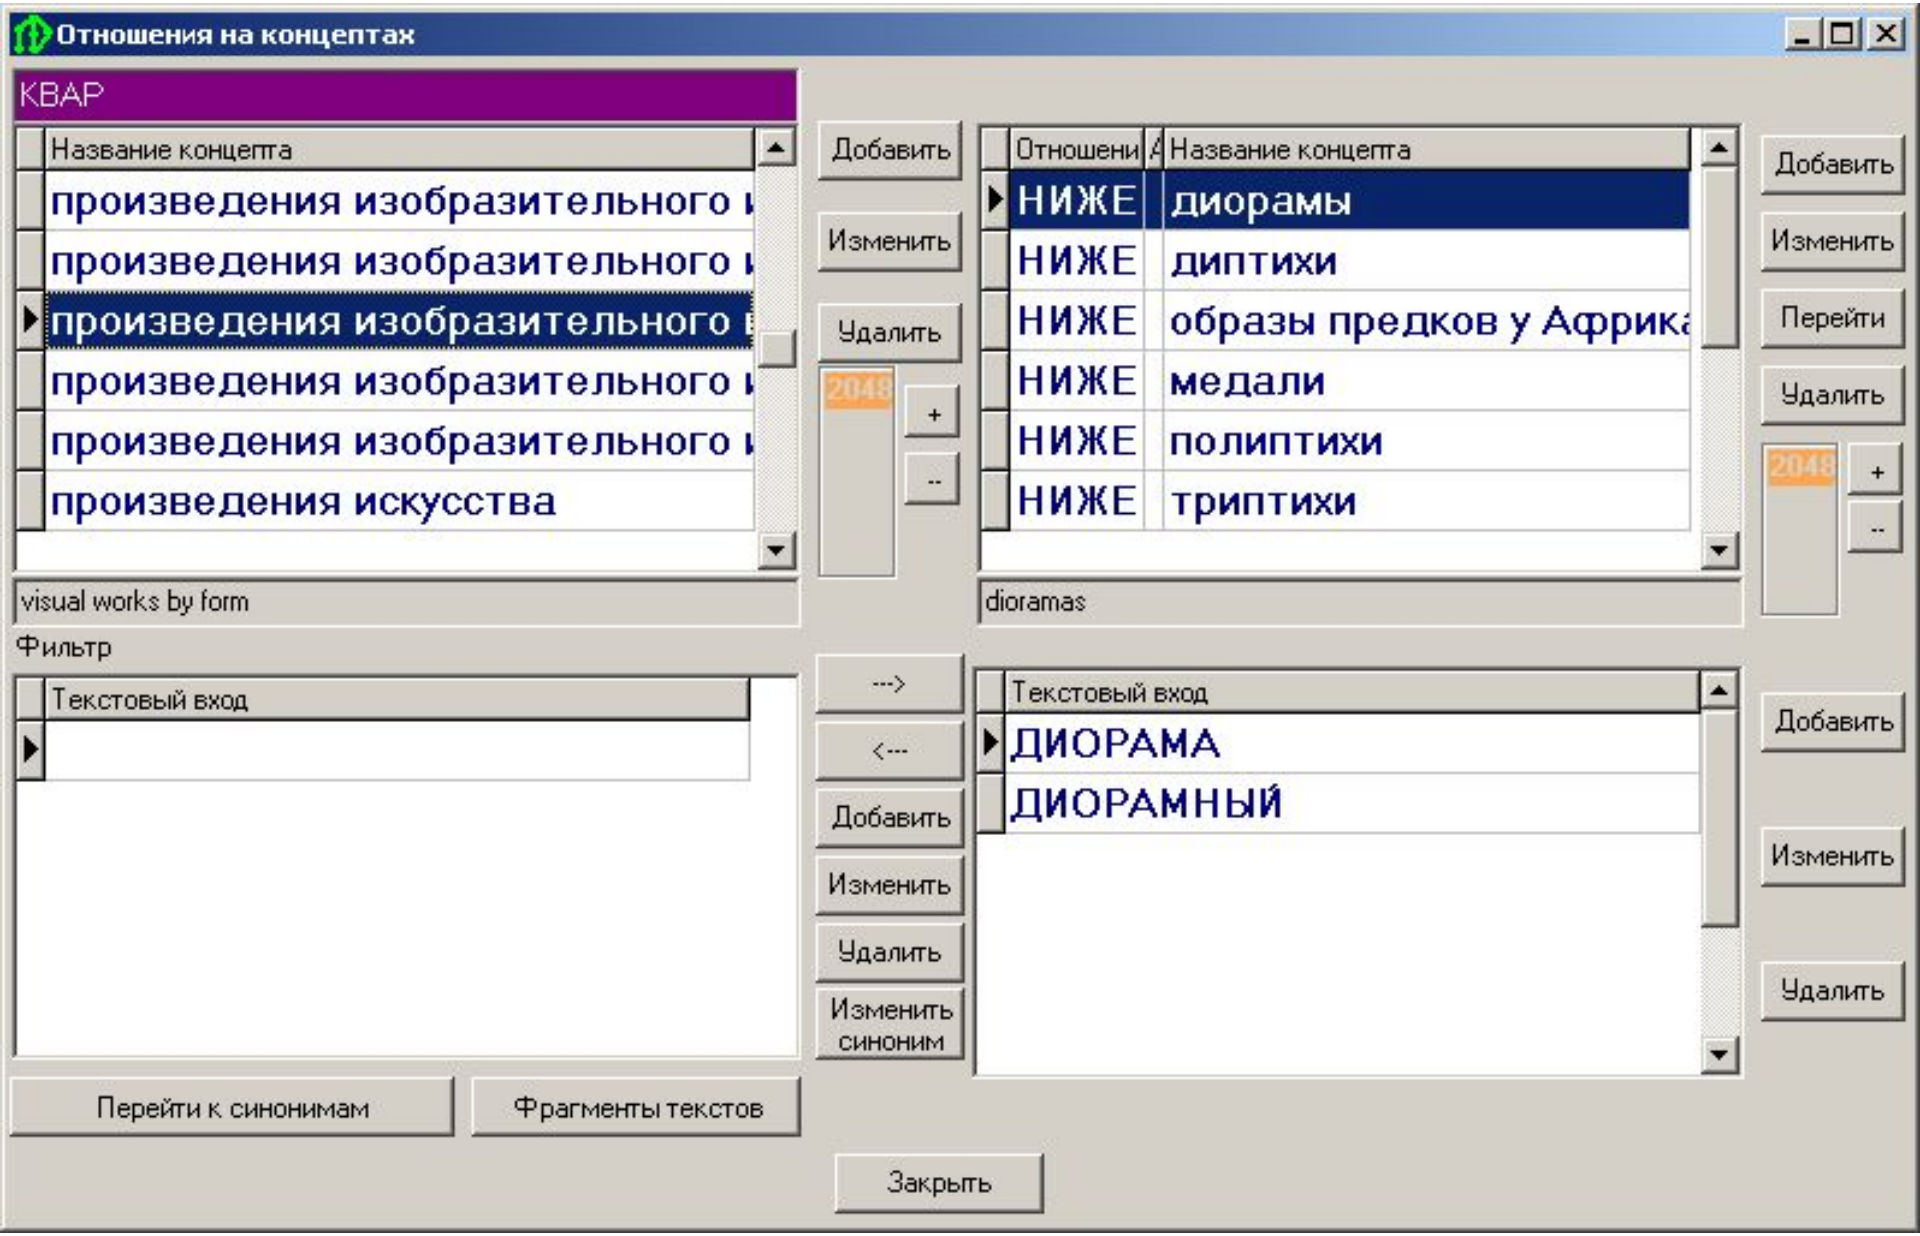

Примеры из коллекции Казанского этнографического музея

- **Кукла из бумаги. Лицевая сторона обтянута шёлком**
- **Обезьяна, голубые глаза из бисера, покрыта кожей с волосяным покровом.**
- **Куша. Тело из пестряди. Платье из иранского ситца, с поясом.**
- **Кукла; юбка непропорционально длинная, красного цвета. Голова покрыта платком из красного ситца.**
- **Кукла. Платье из коричневой ткани. Волосы из пакли, заплетены в косу.**
- **Кукла тряпичная. Сарафан из старой ткани розового цвета. Фартук и кофта из красного ситца с беленькими цветочками. На голове розово-белый платок.**

Экранная форма ввода описания предмета

УИС РОССИЯ университетская информационная система РОССИЯ

Лингвистика России. Ресурсы для исследователей.
Информационная система по культурному наследию России.

USER: **FREE**
Доступ:
FREE
Имя: Пароль:

Регистрация

Забыли пароль?

WWW.CIR.RU

ПОИСК

Автоматическое описание через дескрипторы Тезауруса AAT (The Art & Architecture Thesaurus)

◉ Введите текст:

Кукла; юбка непропорционально длинная, красного цвета. Голова покрыта платком из красного ситца.

Кукла. Платье из коричневой ткани. Волосы из пакли, заплетены в косу.

Кукла тряпичная. Сарафан из старой ткани розового цвета. Фартук и кофта из красного ситца с беленькими цветочками. На голове розово-белый платок.

Кукла в красном ситцевым сарафане, чёрном кафтане и чёрной повязке.

Кукла малая, связанная из соломы. Голова обянута коричневой и белой материей, сшитой в районе затылка. Передник из белой материи.

Молоток деревянный с деревянный наканечником.

○ Загрузить URL: http://

○ Загрузить файл: Browse...

☐ "давить" ссылки

Обработать! Очистить Справка

Пример работы терминологического анализа

hair	ВОЛОСЯНОЙ ПОКРОВ
wood	ДЕРЕВЯННЫЙ
cult images	БОЖОК
wood	ДЕРЕВЯННЫЙ
cult images	БОЖОК
headdresses	ШАПКА
triangles	ТРЕУГОЛЬНЫЙ
cult images	БОЖОК
phonograph records	ПЛАСТИНКА
semicircles	ПОЛУКРУГ
wood	ДЕРЕВЯННЫЙ
cult images	БОЖОК
headdresses	ШАПКА
dresses	ПЛАТЬЕ
chintz	СИТЕЦ
puppets	КУКЛА
skirts	ЮБКА
kerchiefs	ПЛАТОК
chintz	СИТЕЦ

Результаты автоматической обработки

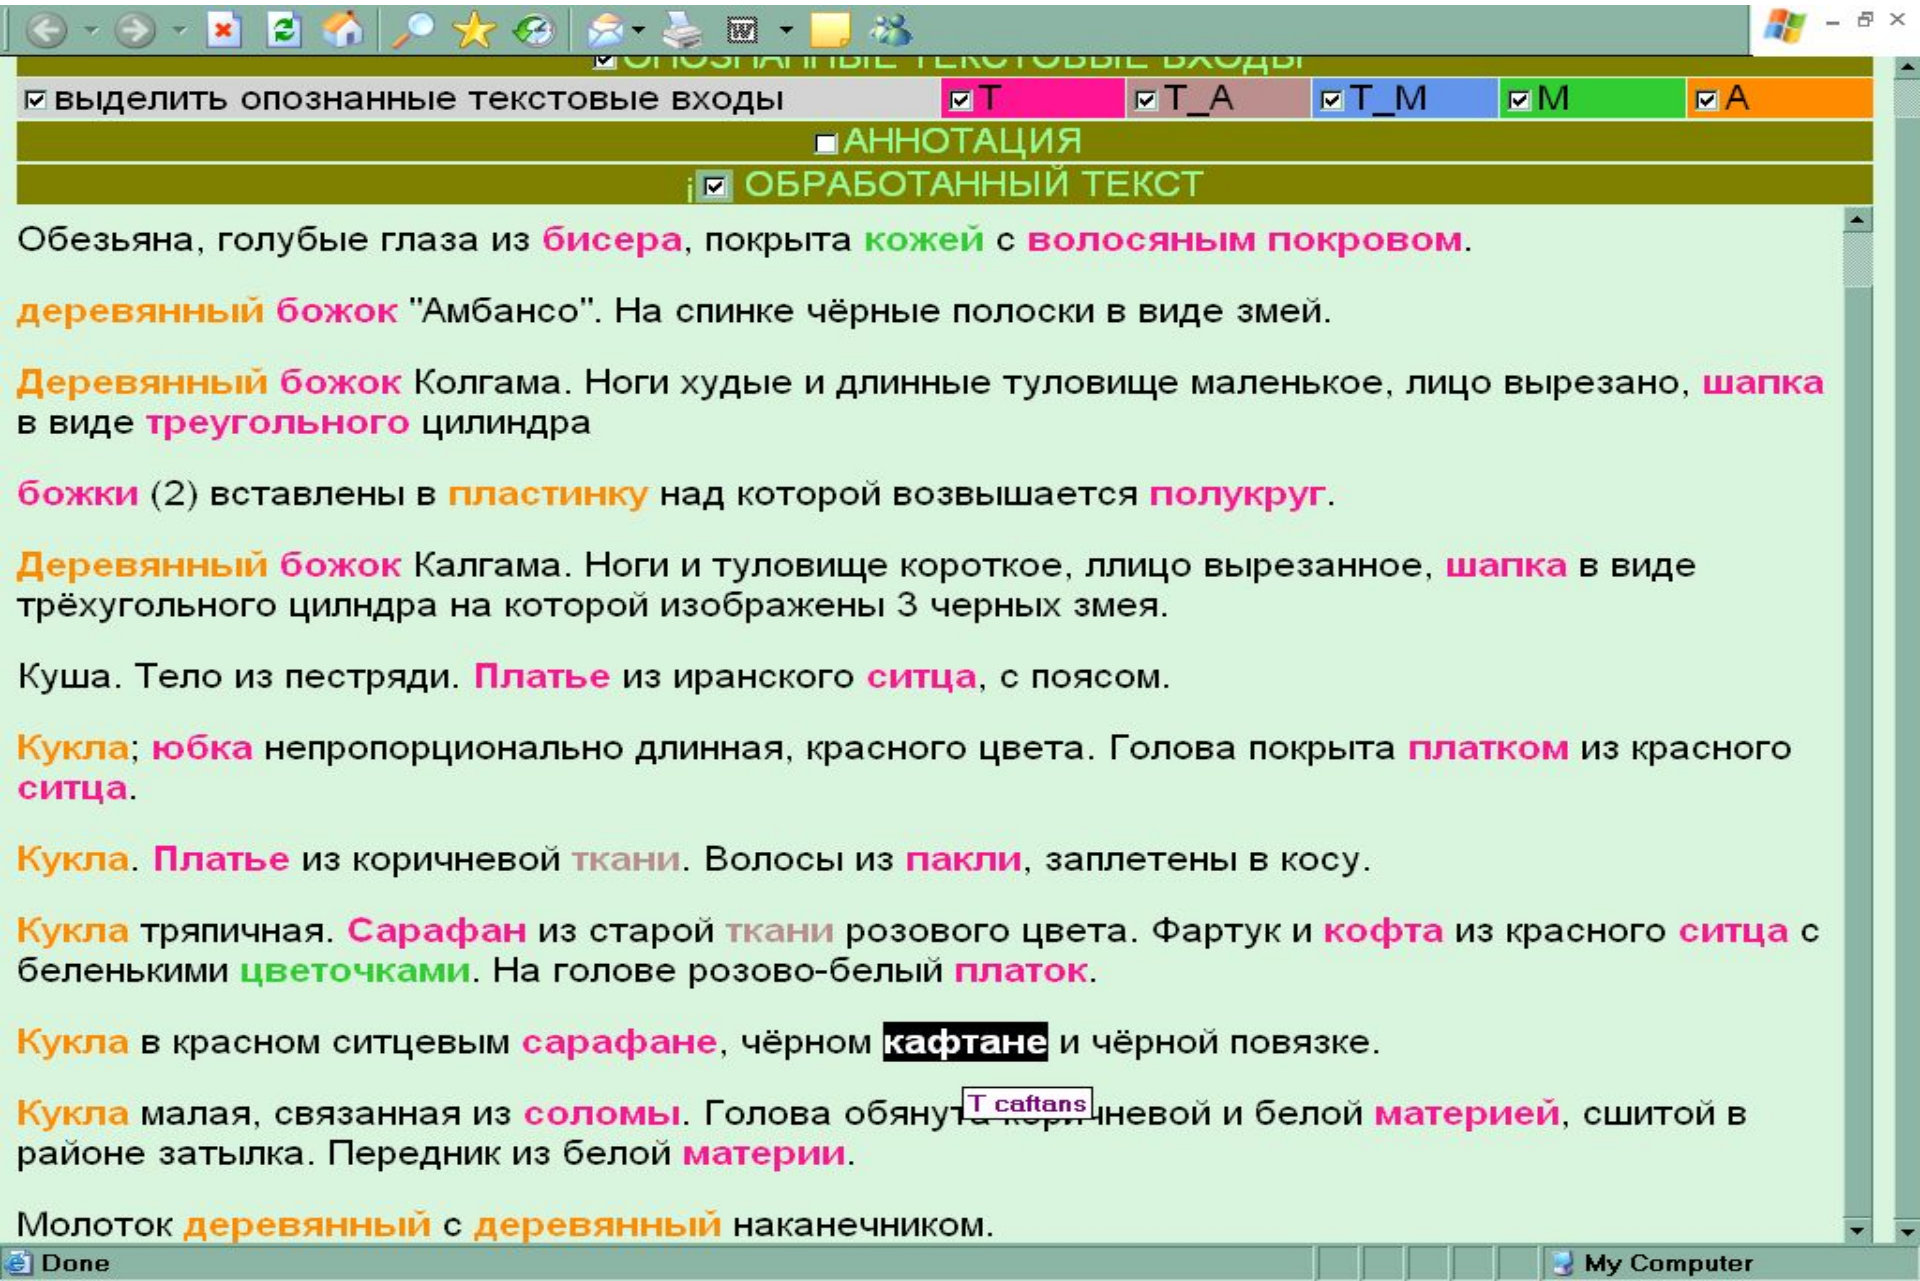

Заключение

- **Тезаурус по архитектуре и искусству – важный источник общезначимых терминов в сфере материальной культуры**
- **Для адаптации тезауруса AAT для описания объектов материальной культуры России: необходим не только перевод на русский язык, но и пополнение русскоязычными синонимами и специфическими терминами**
- **Существенной базой для автоматизированного пополнения могут служить электронные коллекции текстов музеев: каталоги, описания**
- **Сотрудничество: наш опыт работы автоматической обработки текстов, разработки тезаурусов + музеи: коллекции, терминология=> двуязычный тезаурус по архитектуре и искусству**