Методы интеллектуального анализа данных и некоторые их приложения

д.ф.-м.н. И.В.Машечкин (mash@cs.msu.su),
к.ф.-м.н. М.И. Петровский (michael@cs.msu.su)

лаборатория «Технологий программирования»
ВМиК МГУ им. М.В. Ломоносова

(http://synthesis.ipi.ac.ru/sigmod/seminar/s20090226)

Эволюция технологий хранения и обработки данных

- … — 1960-е:
  - Файлы и файловые архивы
- 1960-е:
  - Первые СУБД, иерархические, сетевые и т.д.
- 1970-е:
  - Реляционная модель данных, реляционные СУБД
- 1980-е:
  - «Продвинутые» СУБД (объектно-реляционные и объектные, «расширенные» реляционные, дедуктивные и д.р.)
  - «Специализированные» СУБД (гео-,научные, инженерные и д.р.)
- 1990-е — …:
  - Мультимедийные БД, WWW, хранилища,
  - витрины данных,OLAP, Data Mining

Актуальность и необходимость интеллектуального анализа данных

- Проблема больших объемов («Data explosion»):
  - Средства автоматического сбора данных, повсеместное внедрение СУБД, электронный документооборот, WWW, мультимедийные архивы и т.д. Все ведет к росту объемов и усложнению структуры хранимой информации.
- Традиционные средства не справляются:
  - Информационный поиск и стат. анализ не везде помогают – много данных, сложная структура и нужно знать точно, что искать.
  - Вывод: много данных, но мало информации для аналитика.
- Необходимо:
  - Разработка программных средств автоматизированного анализа данных большого объема и сложной структуры.

Интеллектуальный анализ данных (Data Mining)

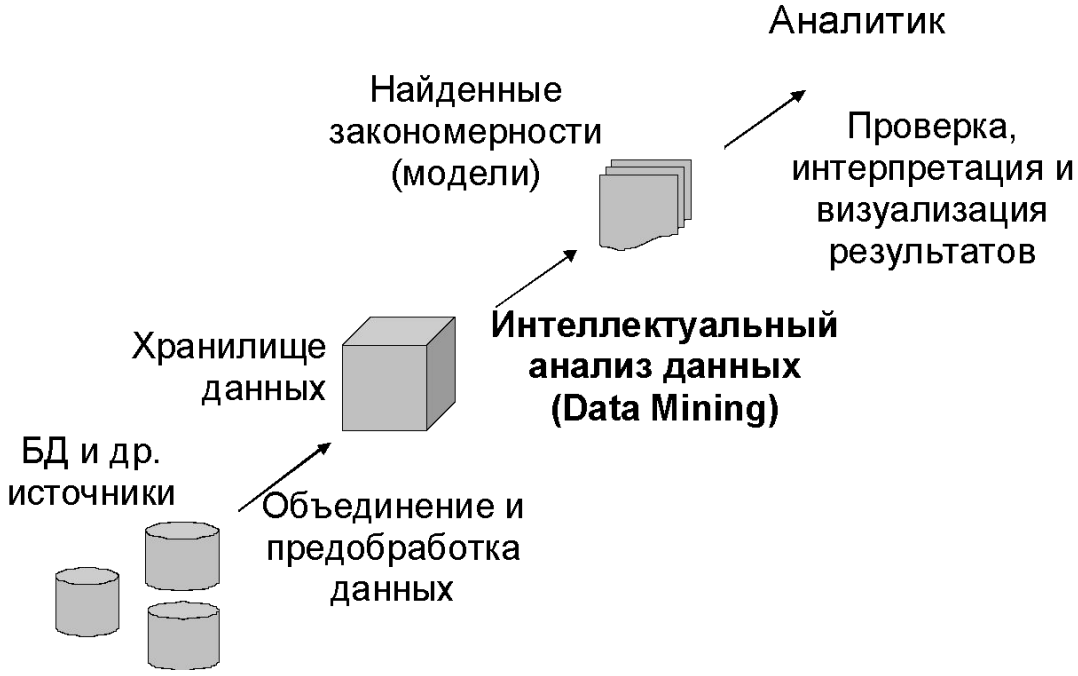

Системы *интеллектуального анализа данных* (ИАД) – класс программных систем поддержки принятия решений, задачей которых является поиск *скрытых, ранее неизвестных, содержательных и потенциально полезных* закономерностей в *больших объемах разнородных, сложно структурированных* данных.

Han J., Kamber M. Data Mining: Concepts and Techniques // Morgan Kaufmann, 2000

Процесс ИАД (1)

- Анализ предметной области:
  - выявление и формулировка необходимых априорных знаний о предметной области, целей анализа, задач приложения, сценариев использования
- Формирование и подготовка данных для анализа:
  - поиск (или выбор) «сырых» данных, возможно реализация подсистемы сбора (консолидации)
  - предобработка данных (нормализация, дискретизация, обработка пропущенных значений, удаление артефактов, проверка консистентности)
  - уменьшение размерности, выбор значимых характеристик, расчет интегральных показателей и инвариантов
- Определение типа решаемой задачи анализа:
  - классификация, прогнозирование, кластеризация, поиск исключений, ассоциативный анализ и т.д.

Процесс ИАД (2)

- Выбор (или разработка) алгоритма анализа:
  - определение ограничений и требований к алгоритму по точности, размеру, интерпретируемости, скорости построения и применения получаемых моделей, по типу исходных данных
- Собственно «Data mining»:
  - применение выбранного алгоритма анализа для поиска закономерностей выбранного типа и построение моделей
- Проверка моделей и представление результатов анализа:
  - визуализация, преобразование, удаление избыточности, оценка точности, достоверности моделей и т.д.
- Применение построенных моделей:
  - Descriptive data mining - информирование аналитика, «описательные» модели, основная цель – визуализация
  - Predictive data mining – прогнозирование неизвестных значений или характеристик в «новых» данных с помощью построенных моделей , основная цель – прогноз

Программные системы ИАД

- Типовая архитектура:

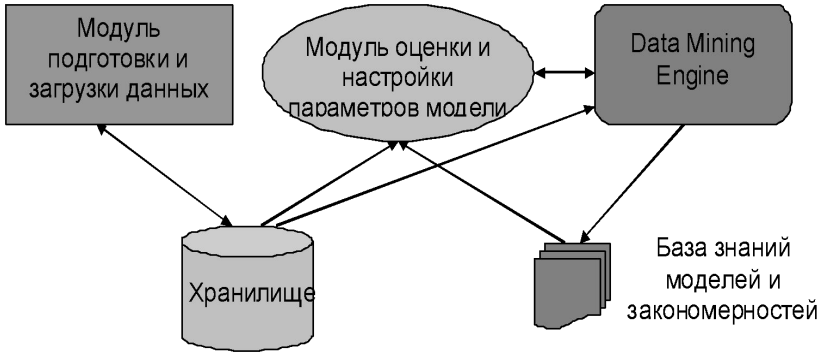

- Классификация систем ИАД:
  - По типу анализируемых данных
  - По типу решаемых задач
  - По методам анализа и классам алгоритмов
  - По области применения

Типы исходных данных (1)

- Транзакционные базы данных и репозитории «событий»
  - Объекты анализа – «события» различной структуры с числовыми и категориальными атрибутами, и с временной меткой
- Реляционные и объектные СУБД
  - Объекты анализа сложным образом взаимосвязаны (заданно ER-схемой), имеют разнотипные атрибутами, наследование (расширение)
- Многомерные OLAP-хранилища
  - Объекты анализа – срезы многомерно OLAP куба, т.е. набор числовых мер, при фиксированных значениях измерений
- Временные ряды и числовые данные большого объема
  - Обработка результатов наблюдений, научных экспериментов, характеристик технологических процессов

Типы исходных данных (2)

- Географические и пространственные данные
  - Привязка к пространственным координатам, учет географии объектов при анализе (например при определении меры сходства или расстояния) , учет перемещения в пространстве (moving objects)
- Символьные последовательности
  - ДНК цепочки, машинные коды, трассы выполнения процессов, тексты программ на ЯП
- Электронные тексты на естественном языке
  - анализ содержимого документов, проблема представления, морфология
- Гипертекстовые данные и WWW
  - структурированный текст на естественном языке, учет гиперссылок и нетекстового содержания
- Мультимедия
  - Звук, видео, изображения

Задачи ИАД = типы выявляемых закономерностей

- Классификация («Обучение с учителем»)
  - Отнесение объектов к заранее определенным категориям
- Прогнозирование («Обучение с учителем»)
  - На основании известных значений атрибутов анализируемого объекта определяются значения неизвестных атрибутов
- Ассоциации («Обучение без учителя»)
  - Выявление зависимостей между атрибутами
- Кластеризация («Обучение без учителя»)
  - Выделение компактных подгрупп «похожих» объектов
- Дискриминантный анализ («Обучение без учителя»)
  - Выявление атрибутов который «различают» (дискриминируют) две или более возникающие совокупности (группы)
- Выявление исключений («Обучение с и без учителя»)
  - Поиск объектов, которые своими характеристиками значительно отличаются от остальных

Методы анализа

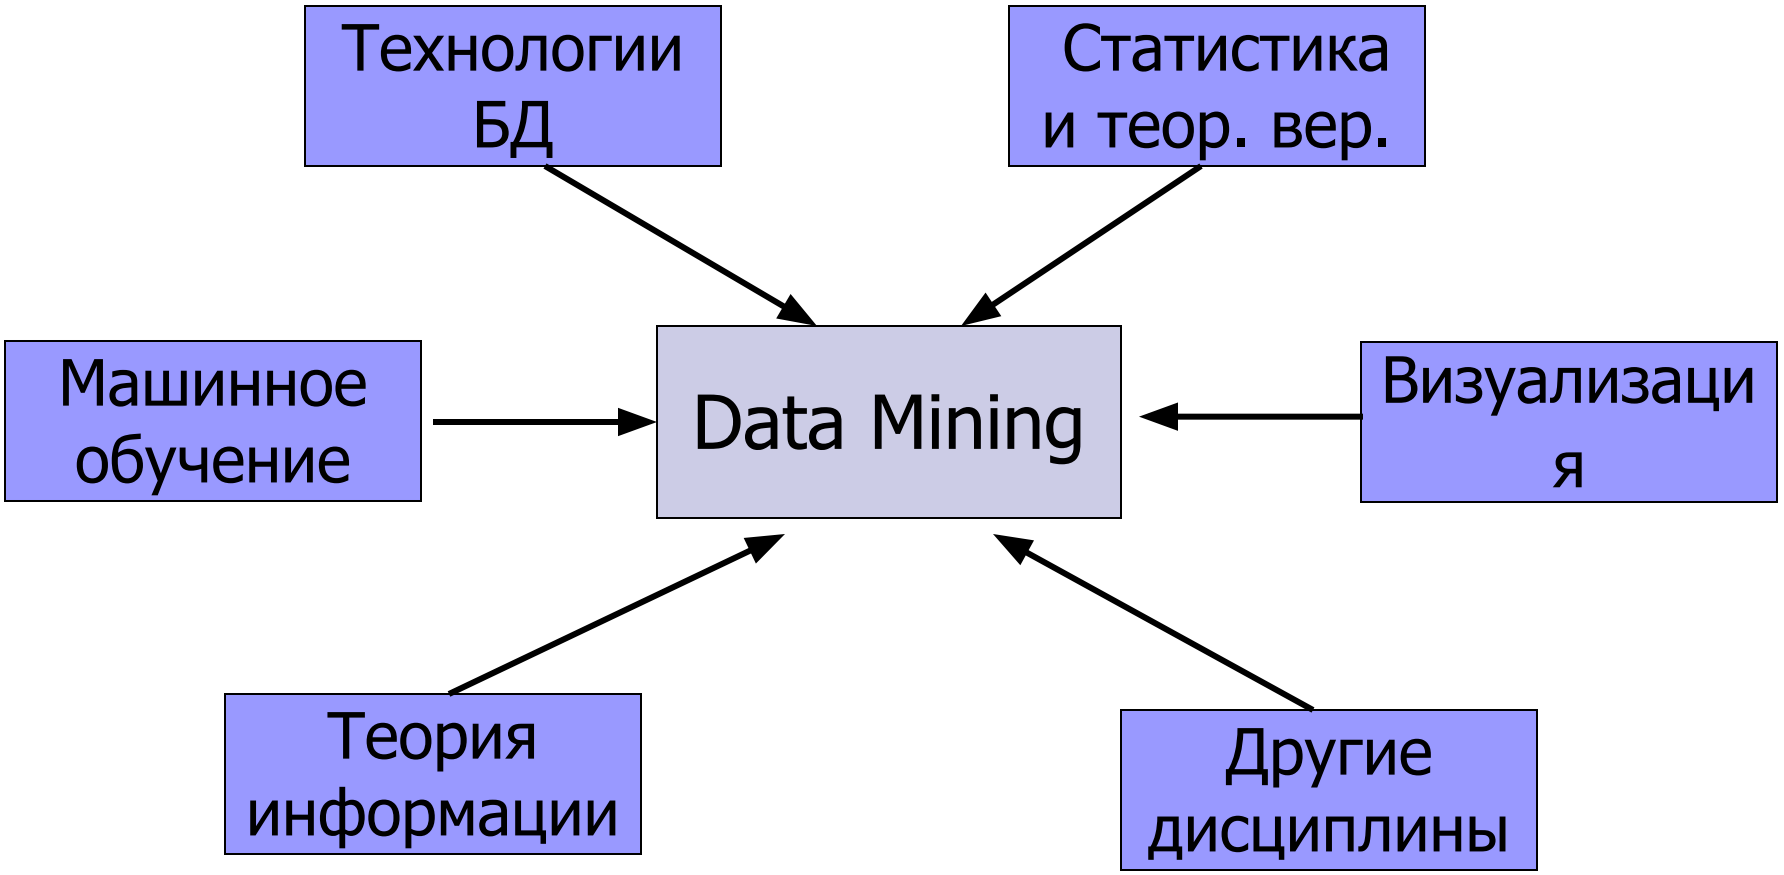

Область применения систем ИАД

- Системы ИАД «общего назначения»
  - По сути включают framework, библиотеку алгоритмов анализа и набор программных средств для реализации ИАД процесса для широкого класса входных данных и прикладных задач
  - Примеры DataMiner, MS Analysis Services, Oracle BI, PolyAnalyst
- Специализированные системы ИАД
  - Набор решаемых задач и алгоритмов решения, а также средств подготовки данных и визуализации результата ориентирован на конкретную предметную область
  - ИАД процесс максимально «автоматизирован», но конечным потребителем информации все равно является эксперт-аналитик
  - Области применения: маркетинг, анализ финансовых рисков, здравоохранение, страхование, кредитование, телекоммуникации, компьютерная безопасность, мониторинг оборудования и технологических процессов, антитерроризм, интернет и т.д.

Отличия ИАД систем (1)

- Наличие «обучения»
  - база знаний формируются на основе анализируемых данных, а не экспертных знаний (в отличии от традиционных экспертных систем и систем информационного поиска)
  - структура модели и искомые зависимости заранее не известны (в отличии от статистических пакетов, ориентированных на расчет статистик, проверку гипотез и оценку параметров распределений)

Отличия ИАД систем (2)

- Наличие большого объема данных сложной структуры
  - зачастую скорость работы алгоритмов в ИАД важнее небольших отклонений по точности (“quick and dirty solution”)
  - большинство алгоритмов работают с исходными данными в виде числовой матрицы признаков, сложная структура реальных объектов в ИАД, приводит к необходимости решать задачу построения пространства характеристик и отображения в него свойств исходных объектов
  - перечисленные особенности отличают ИАД системы от традиционных систем машинного обучения, в которых как правило решается обратная задача – построение достоверной модели в условиях малой обучающей выборки

Отличия ИАД систем (3)

- Наличие человека - аналитика как оконечного потребителя результатов работы ИАД системы
  - в сценарии работы любой системы ИАД всегда присутствует аналитик, даже если полученная в результате модель далее используется для автоматической классификации
  - аналитик формирует тренировочные наборы, производит настройку алгоритмов, обучение и дообучение, анализирует полученные модели и принимает решения об их дальнейшем использовании
  - таким образом, системы автоматические классификации, кластеризации и распознавания образов, даже использующие возможность дообучения, не являются системами ИАД

ИАД в проектах лаборатории «Технологий Программирования»

- Компьютерная безопасность
  - Обнаружение внешних и внутренних вторжений
  - Моделирование и анализ поведения пользователей
- Электронный документооборот
  - анализ и фильтрация электронной почты и Web трафика
  - рубрикация и аннотирование электронных документов организации
- Технологические процессы и производство
  - выявление нештатных ситуаций
  - прогнозирование качества продукции
- Системы поддержки принятия решений
  - использование ИАД в ПО ситуационных центров

ИАД в компьютерной безопасности

- Цели компьютерной безопасности: обеспечение конфиденциальности, целостности и доступности данных
- Вторжение – действия программы или пользователя, направленные на нарушение целей компьютерной безопасности
- Традиционные методы предотвращения вторжений (авторизация, разграничение прав доступа, криптозащита и т.д.) не справляются
- Необходимо выявление вторжений

Традиционные средства выявления вторжений

- Основные концепции:
  - Используют базах сигнатур известных атак
  - Источники информации: системные журналы и файлы, содержимое сетевого трафика и файлов.
- Недостатки:
  - Базы знаний формируются экспертами
  - Необходимо периодически обновлять
  - Существенная задержка во времени между появлением новой атаки и средств защиты от нее
  - Атаки постоянно видоизменяются
  - Есть методы «маскировки» атак

Методы ИАД в задачах выявления вторжений

- Основное предположение:
  - активность пользователей и программ можно полностью отследить и построить ее адекватную модель
- Особенности:
  - накопление исторической информации
  - модели нормального поведение или вторжения
  - эффективные методы анализа, которые проверяют текущую активность в системе на соответствие построенным моделям

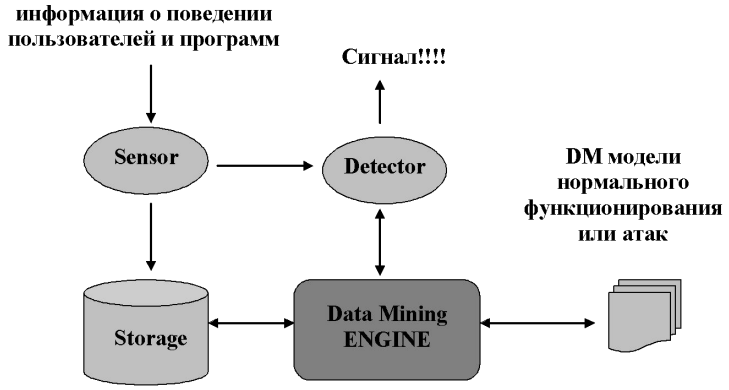

Обнаружение нарушений

- Особенности:
  - Строится обобщенная модель атаки
  - Основано на методах классификации
  - Атакой считаются события или последовательности событий, соответствующие модели
- Основные проблемы:
  - «Обучение с учителем»: модель строится на примерах атак (необходимо их иметь и выделть из общей массы данных «вручную»)
  - Невозможно обнаруживать абсолютно новые или хорошо «замаскированные» атаки

Обнаружение аномалий

- Особенности :
  - Строится обобщенная модель нормальной активности пользователей или программ (профайл)
  - Основано на методах поиска исключений
  - Атакой считаются события или последовательности событий, несоответствующие модели
- Основные проблемы:
  - Предположения («Обучение без учителя»):
    1. обычные события отличаются от атак
    2. атак не больше p% от всех тренировочных данных, где p мало или равно 0 (обычно p неизвестно)
  - Высокий уровень ошибок второго рода (false positive)

Разработанные и реализованные алгоритмы

- Обнаружение аномалий:
  - Оценка степени «типичности» событий и их последовательностей - нечеткая кластеризация в бесконечномерном пространстве характеристик.
- Обнаружение нарушений:
  - Гибридный метод – Нечеткий SVM (Fuzzy Support Vector Machine) в сочетании с предыдущим методом
- «Описательные» модели поведения пользователей:
  - Вероятностная модель поведения пользователя на основе деревьев решений и отображения множества ситуаций (последовательностей событий) в пространство характеристик с помощью потенциальных функций
- Верификация:
  - На реальных данных и на эталонных тестовых наборах DARPA и др.

Система мониторинга и анализа поведения пользователей

- Функциональность:
  - Сбор и консолидация данных о работе пользователей
  - Статистический и интеллектуальный анализ
  - Построение и визуализация моделей поведения
  - Поиск аномалий в работе пользователей
- Области применения:
  - Выявление инсайдеров и предотвращение утечек информации
  - Поиск и анализ последствий вторжений
  - Система «раннего предупреждения»
  - Анализ производительности и целевого использования пользователями вычислительных средств организации

Архитектура системы мониторинга

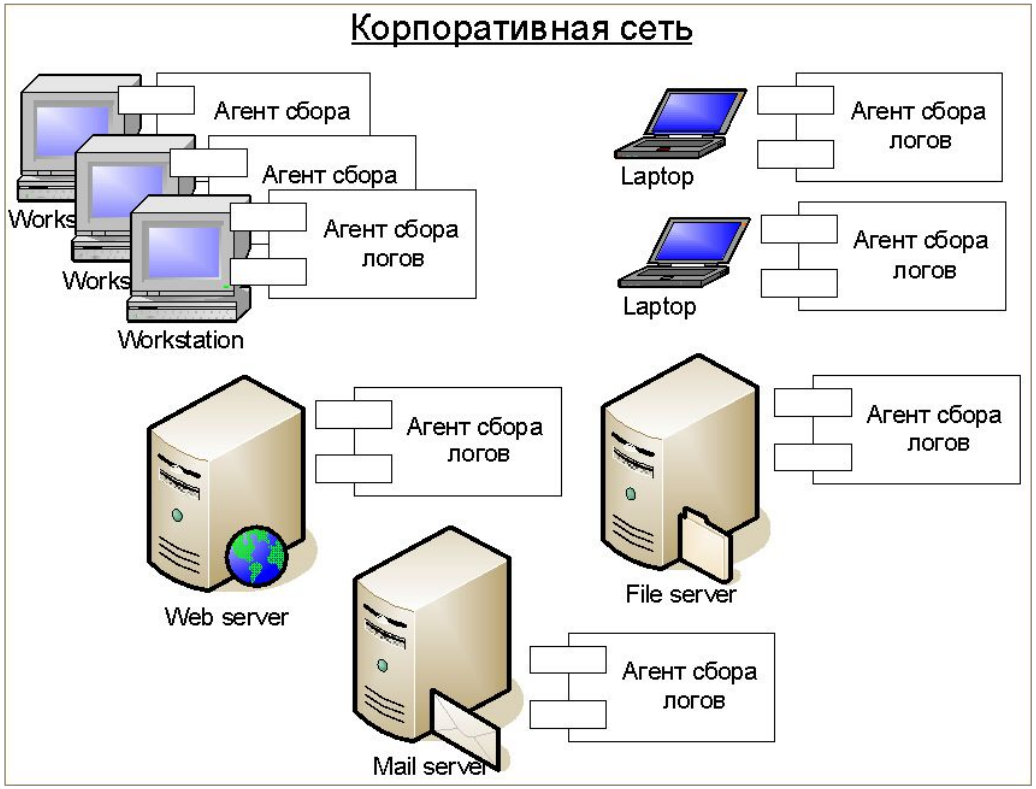

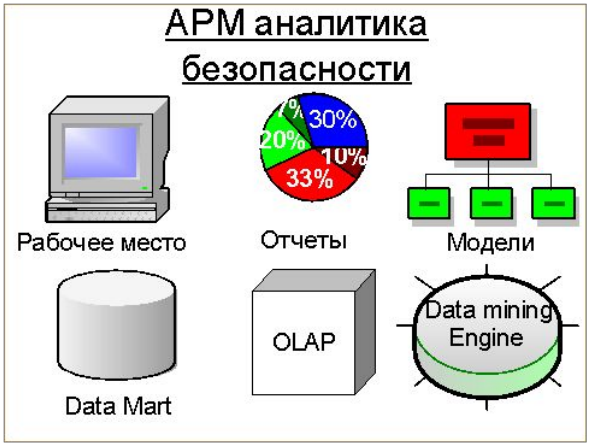

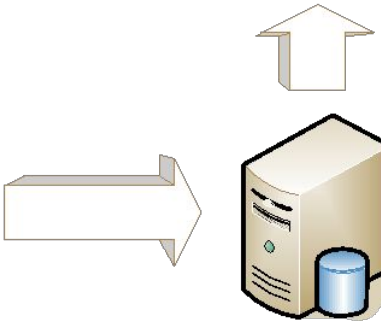

Сервер консолидации и хранения событий безопасности

Особенности реализации и результаты

- Подсистема консолидации исходных данных:
  - Мульти-агентный подход
  - Нет ограничений на источники собираемых данных
  - Универсальный интерфейс для работы с модулями сбора данных
  - Специализированный формат представления собранных данных
  - Специализированное отказоустойчивое высоко производительное хранилище данных на файловой системе
  - Специальная предобработка данных
- Анализируемые факты:
  - Вход/выход в систему, запуск пользовательских и системных процессов, доступ к данным на любых носителях, активность пользователей в приложениях (клавиатура, мышь), входящий/исходящий сетевой трафик
- Опытная эксплуатация:
  - В ряде коммерческих и государственных организаций прошло опытное внедрение

Электронный документооборот

- Интеллектуальная система анализа и фильтрации электронной почты масштаба предприятия
- Система анализа и много-темной классификации Web трафика
- Интеллектуальная систему теневого копирования, рубрикации и аннотирования электронных документов организации

ИАД для системы анализа и фильтрации электронной почты

- Алгоритм классификации (на SVM):
  - векторная форма представления письма
  - высокая точность
  - эффективность по скорости
  - персональная модель классификации почты
- Предобработка данных:
  - Снижение размерности исходного пространства (хи-квадрат и PCA)
  - Уменьшение размера тренировочного набора - кластеризация

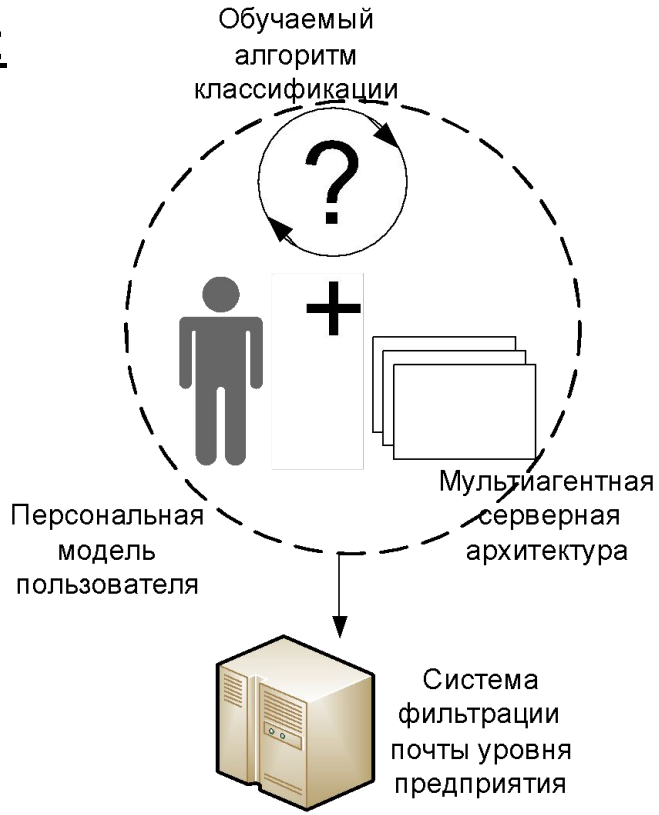

Архитектура системы фильтрации

- Особенности реализации:
  - Учет ресурсоемкости алгоритмов на этапе обучения
  - Распределение и баланс нагрузки
  - Классификация в режиме реального времени
  - Возможность масштабирования
  - Возможность интеграции с различными почтовыми системами

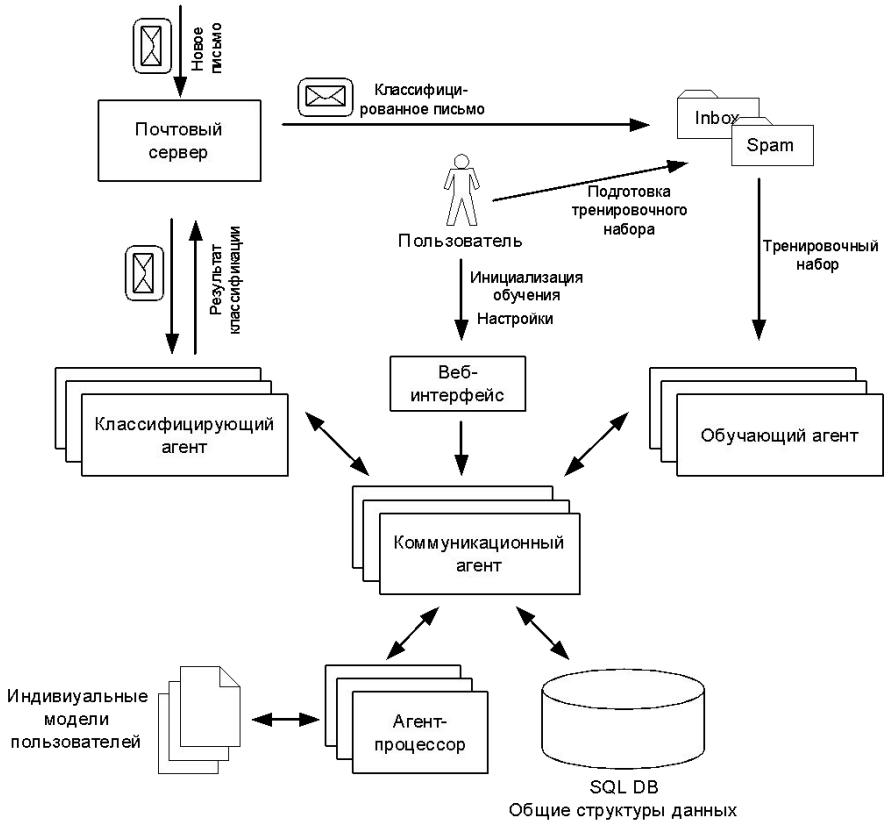

Результаты экспериментальной реализации и апробации

- Почтовый сервер лаборатории «Технологий программирования»
  - эксплуатация с весны 2004
  - около 1 тыс. писем в день (после RBL)
  - из них > 70% спам
  - уровень обнаружения более 95%
  - уровень ложно-положительных ошибок ~ 0.1%
- Почтовый сервер факультета ВМиК, МГУ
  - эксплуатация с осени 2004

Цели создания систем анализа и фильтрации Интернет-трафика

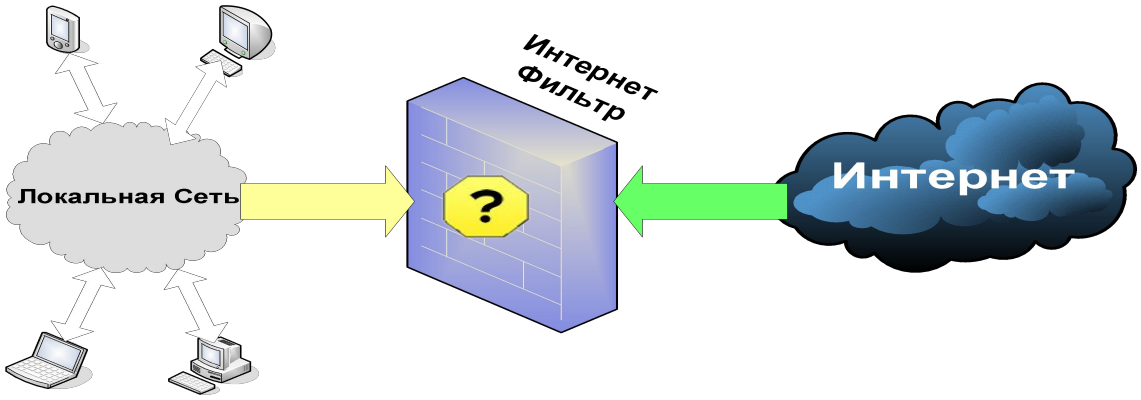

- Блокирование доступа к нелегальной (экстремистской, антисоциальной, террористической и т.п.) информации
- Предотвращение использования Интернет-ресурсов в личных целях в рабочее и учебное время
- Предотвращение утечки конфиденциальной информации (анализ исходящего трафика)

Существующие системы фильтрации

- Традиционный подход («сигнатурные» методы):
  - Использование при анализе Интернет-трафика специализированных, формируемых экспертами, баз знаний, содержащих информацию об Интернет-ресурсах (URL, IP-адреса, ключевые слова)
- Основные недостатки:
  - Ориентированы на ресурсы со статическим содержанием («черные списки» адресов)
  - Возможны ошибки при определении тематики
  - Результаты зависят от качества и оперативности обновления баз знаний
  - Отсутствует анализа исходящего трафика (нет возможности предотвращения утечки конфиденциальной информации)

Анализ и фильтрация Интернет-трафика на основе методов ИАД

- Основная идея:
  - Классификация потока гипертекстовой информации в режиме реального времени с учетом содержания и структуры ссылок документов с использованием методов извлечения и применения знаний (алгоритмы машинного обучения и интеллектуального анализа данных).
- Функционирование:
  - Администратор формирует тренировочный набор с известными тематиками (примеры гипертексовых документов, либо список Интернет-ресурсов, содержимое которых затем откачивает робот);
  - На тренировочном наборе методами машинного обучения строится классификатор, который затем используется Интернет-фильтром в режиме реального времени для анализа содержимого трафика.
- На настоящий момент времени нет таких промышленных решений!

Преимущества

- Классификация в реальном времени статических и динамических интернет ресурсов;
- Точность выше, чем у «сигнатурных» методов;
- Автономность - независимость от внешних экспертов, поддержка собственной автоматически пополняемой базы знаний адресов;
- Адаптируемость - возможность уточнения классификации при поступлении новых примеров;
- Расширяемость - возможность добавлять новые категории и гибко настраивать политики фильтрации.

Архитектура системы

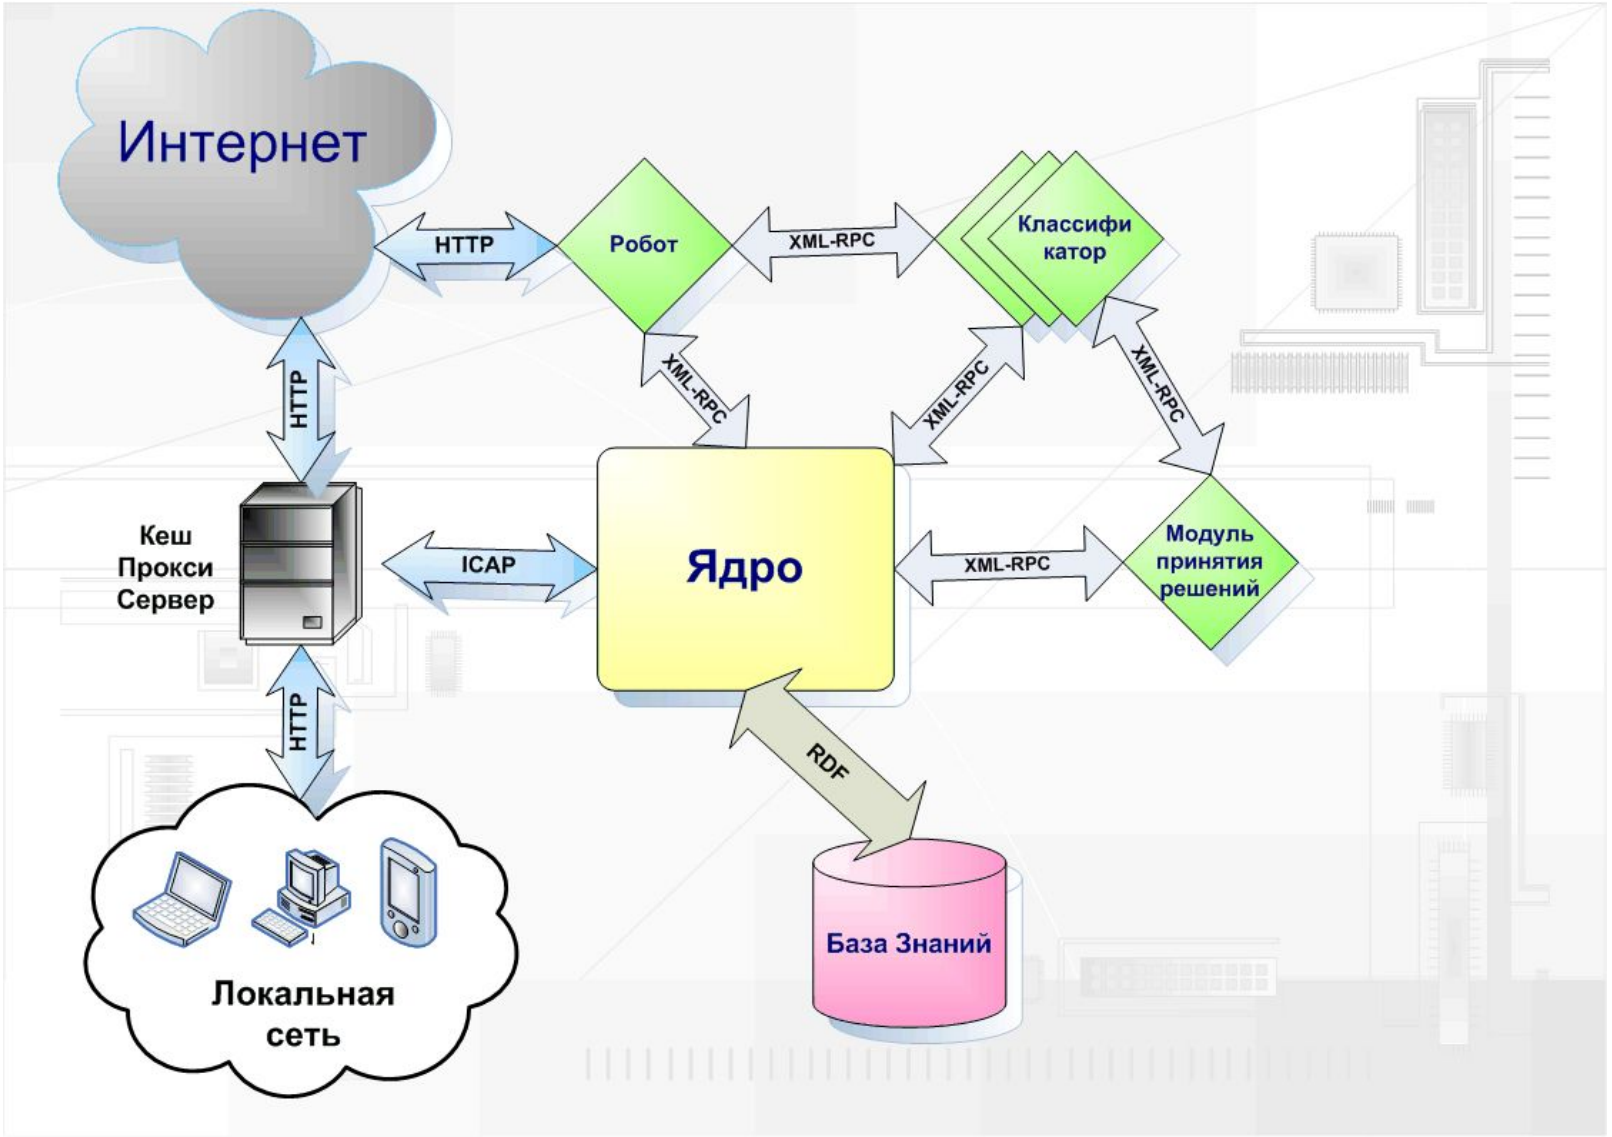

Основные результаты

- Реализация системы:
  - Формализованы требования и сценарии взаимодействия
  - Спроектированы и реализованы базовые компоненты, их функционал, интерфейсы, алгоритмы работы
  - Разработана онтология представления информации об интернет ресурсах и алгоритмы работы с базой знаний
- Разработан новый алгоритм много-темной классификации:
  - на основе модифицированного для существенно пересекающихся классов метода «попарных сравнений» с помощью набора бинарных классификаторов и отсечением нерелевантных классов
- Предложена расширенная векторная модель представления гипертекстовых документов:
  - включает базовые текстовые и нетекстовые признаки, составные признаки (сгруппированные базовые) определяются с помощью метода поиска частых эпизодов
  - новый метод учета гиперссылок (не требует загрузки содержимого «окружения»)

Интеллектуальная система анализа и мониторинга электронного документооборота организации

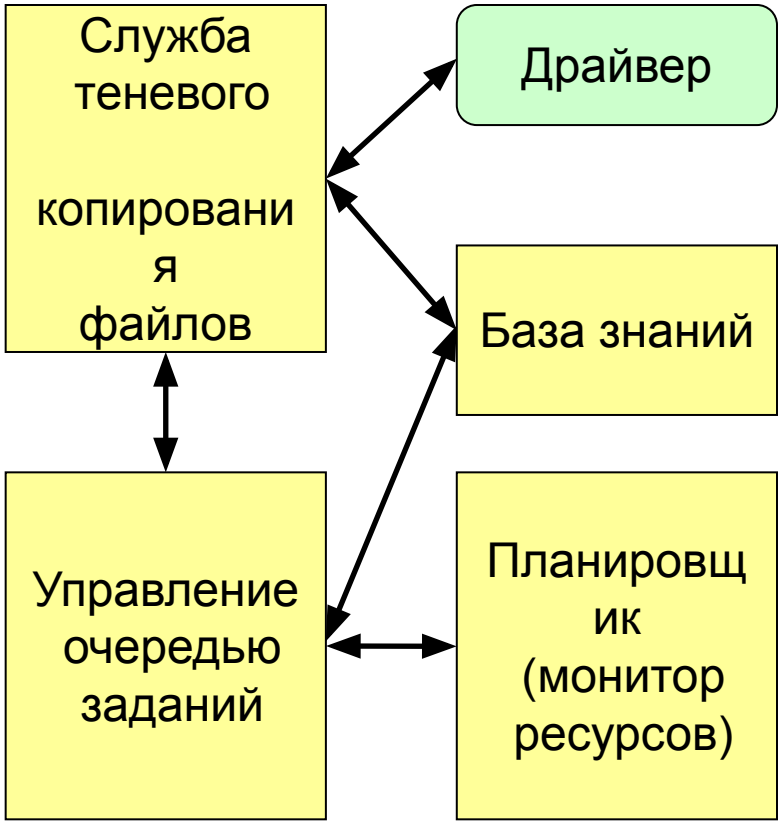

Драйвер ФС: определяет с какими файлами работал пользователь;

Служба теневого копирования: определяет как сильно изменился файл, при необходимости делает резервную копию, передает файл на обработку;

База знаний: хранение резервных копий файлов их аннотаций, служебной информации о кластерах и моделей аннотирования;

Управление очередью заданий: хранит очередь заданий на обработку, при освобождении ресурсов ВС выполняет задания из очереди;

Монитор ресурсов: анализирует загруженность ВС, разрешает выполнять задания из очереди;

Модель аннотирования

- *Кластер документов* – набор «схожих» документов;
- Каждый документ кластера разбивается на *фрагменты текста*;
- Каждый *фрагмен текста* преобразуется в частотный вектор «термов» (слов);

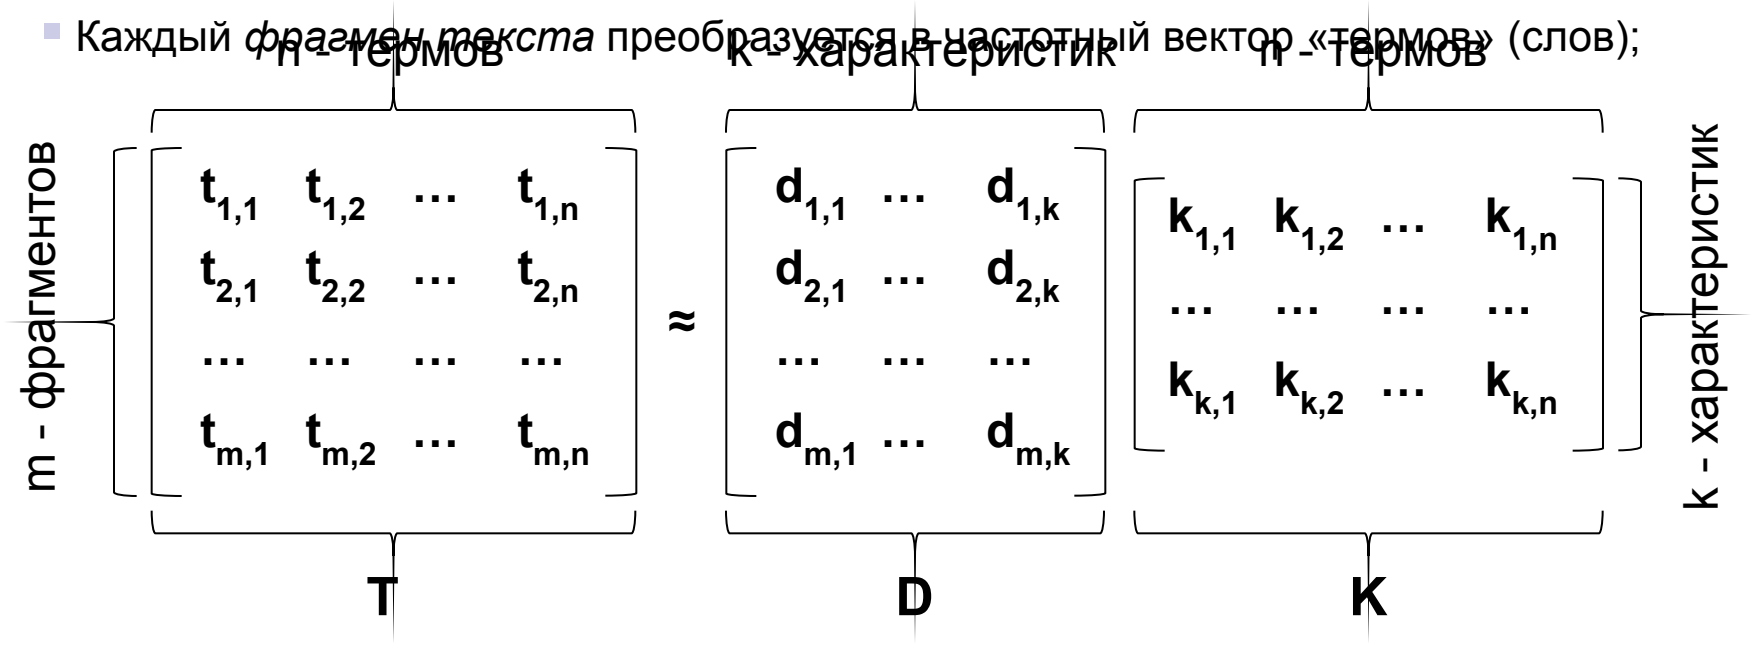

T – исходная матрица фрагментов;

D – матрица фрагментов в пространстве «ключевых» характеристик;

K - матрица перехода, $\mathbf{K}^{-1}$ – *модель аннотирования* (строится для каждого кластера);

Алгоритмы поиска ключевых характеристик

- *Латентно-семантический анализ (LSA - Latent Semantic Analysis):* основан на использовании разложения исходной матрицы по сингулярным значениям (SVD - разложение)
- *Анализ независимых компонент (ICA - Independent component analysis):* поиск линейных комбинаций наблюдаемых переменных ведется чтобы получить независимые случайные величины, распределение которых максимально далеко от нормального
- *Выделение частых эпизодов термов (Apriori):*

  Для выделенных фрагментов документов, строится список характерных частых эпизодов термов.

Аннотирование новых документов

- Для каждого *документа* определяется ближайший кластер и соответствующая ему модель аннотирования;
- Документ разбивается на *фрагменты текста*;
- Каждый *фрагмен текста* преобразуется в частотный вектор «термов» $\mathbf{t}_i$;
- Для каждого частотного вектора «термов» $\mathbf{t}_i$ строится его *проекция* на пространство ключевых характеристик $\mathbf{p}_i$ с помощью модели аннотирования $\mathbf{K}^{-1}$:

$$\mathbf{p}_i = \mathbf{t}_i * \mathbf{K}^{-1};\ \mathbf{K} * \mathbf{K}^{-1} = \mathbf{E};$$

- *Вес фрагмента* определяется как:

$$V_i = \sum_{j=1}^{k} | p_{i,j} |;$$

- *Аннотация* – *n* фрагментов с максимальным весом;

Архитектура ИАД системы анализа поведения технологических процессов

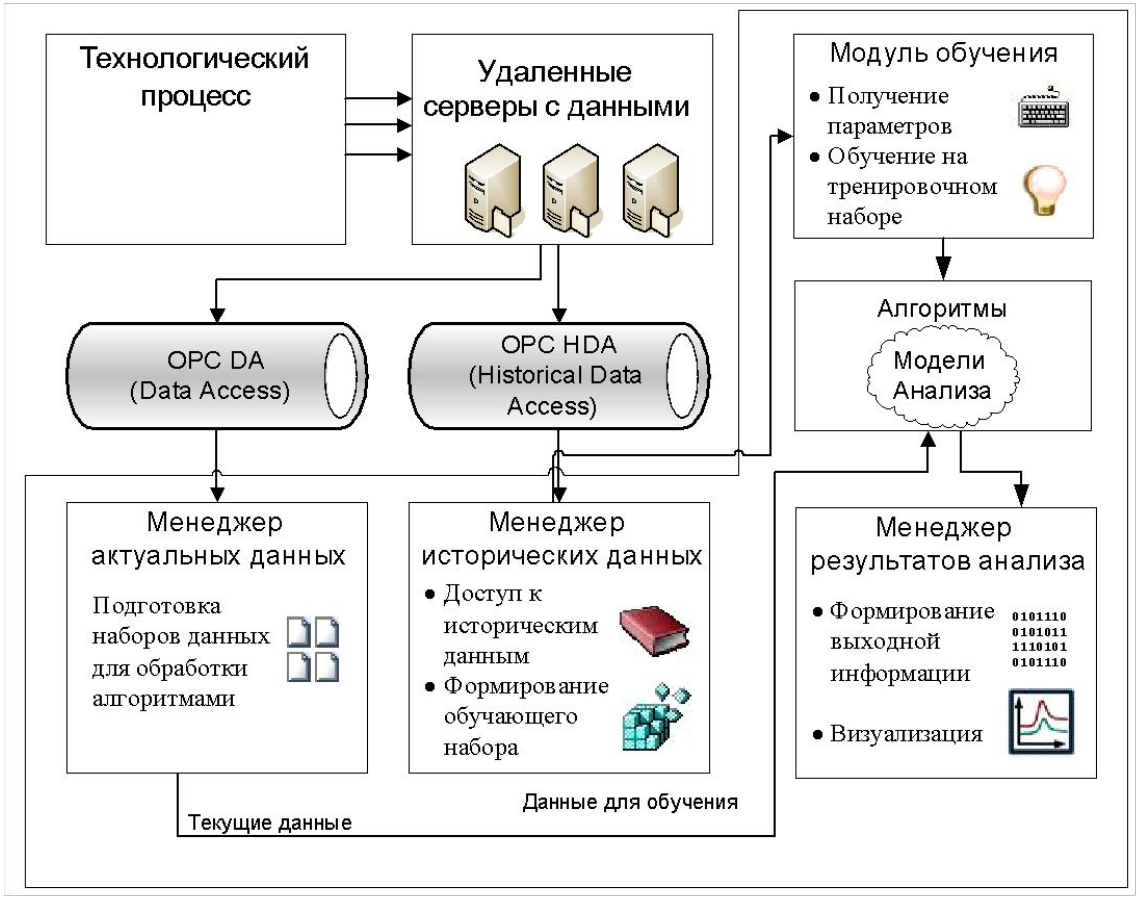

Особенности реализации:

- выявление аномалий в характеристик ТП
- функционирование в промышленной среде
- работа в режиме мягкого реального времени
- расширяемость по набору методов анализа

Выявление нештатных ситуаций

- построение модели поведения ТП (на этапе обучения)
- оценка отклонения текущего состояния ТП от модельного
- используются методы анализа временных рядов и последовательностей:
  - Класса «Гусеница» (Singular Spectrum Analysis)
  - Методы авторегрессии на основе SVR
  - Скрытые модели Маркова
  - и др.

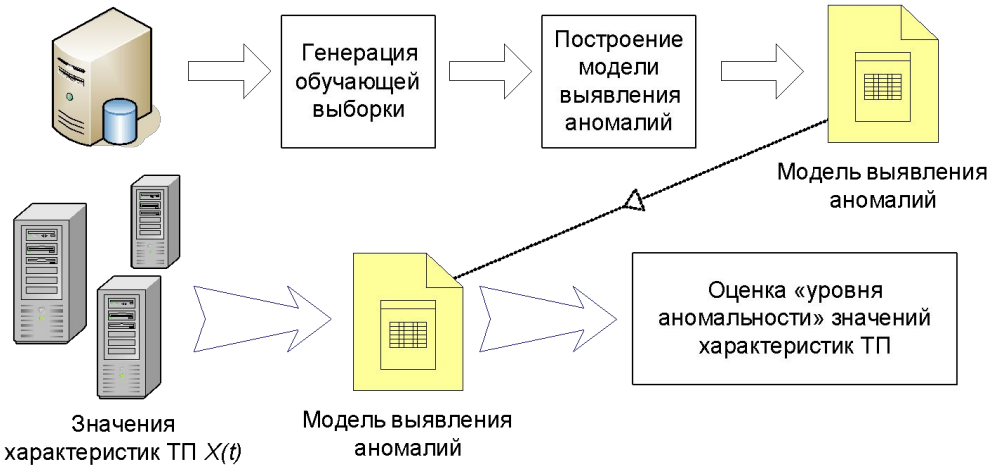

Анализ и прогнозирование качества ТП

Какие параметры производственного процесса влияют на качество продукции?

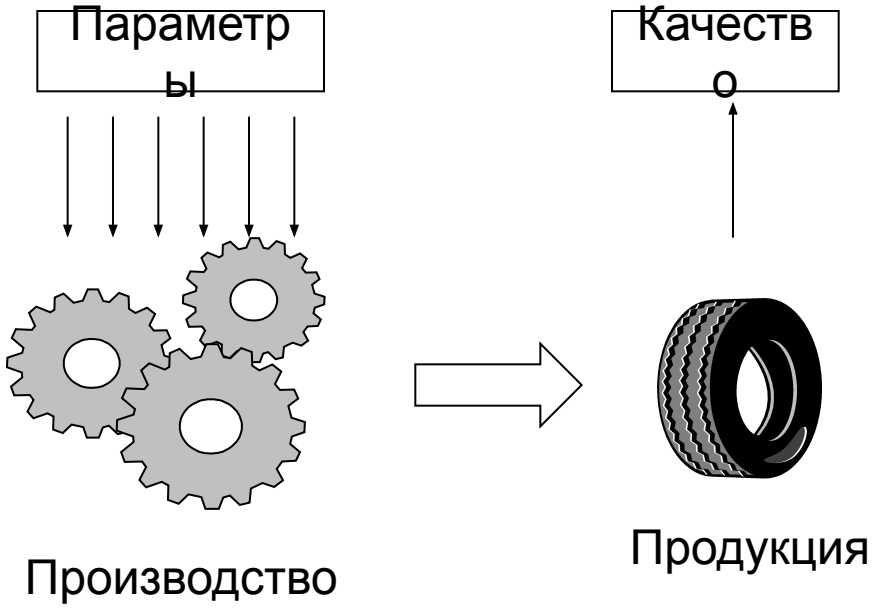

$$Quality = F(X_1, \ldots X_n),$$

где X_i — i-ая характеристика производственного процесса

Результат

- Разработаны алгоритмы:
  - на основе нечетких деревьев решений
  - с поддержкой эволюционных методов оптимизации нечетких переменных и структуры правил
- Реализована экспериментальная программная система:
  - строит модели зависимости качества продукции от характеристик производственного процесса, представимую в виде системы нечетких правил «если … то … иначе»;
  - прогнозирование ожидаемого качества изделия по характеристикам производственного процесса производится с достаточной точностью;
  - позволяет упорядочить характеристики технологического процесса по степени влияния на качество.

Ситуационный центр

- Основная задача СЦ — строить наглядные образы ситуаций, возникающих в предметной области, на основе которых оперативный состав принимает управляющие решения.
  - в СЦ обязательно входит оперативный состав (коллектив потребителей наглядной информации), решающий некоторую совокупность задач, требующих принятия решений;
  - в СЦ создаются информационные модели и картины весьма сложных, комплексных, динамических ситуаций реального мира для представления оперативному состав.
- Определение СЦ: это совокупность программно-технических средств, научно-математических методов и инженерных решений для автоматизации процессов отображения, моделирования, анализа ситуаций и управления.

Место ИАД в процессе поддержки принятия решений в СЦ

Задачи:

- Расчет индикаторов на основе данных предметной области
- Определение тенденций и прогнозирование значений индикаторов
- Выявление аномалий в значениях индикаторов

Расчет и хранение индикаторов

- Проведение статистического анализа и вычисление индикаторов, описывающих ситуацию

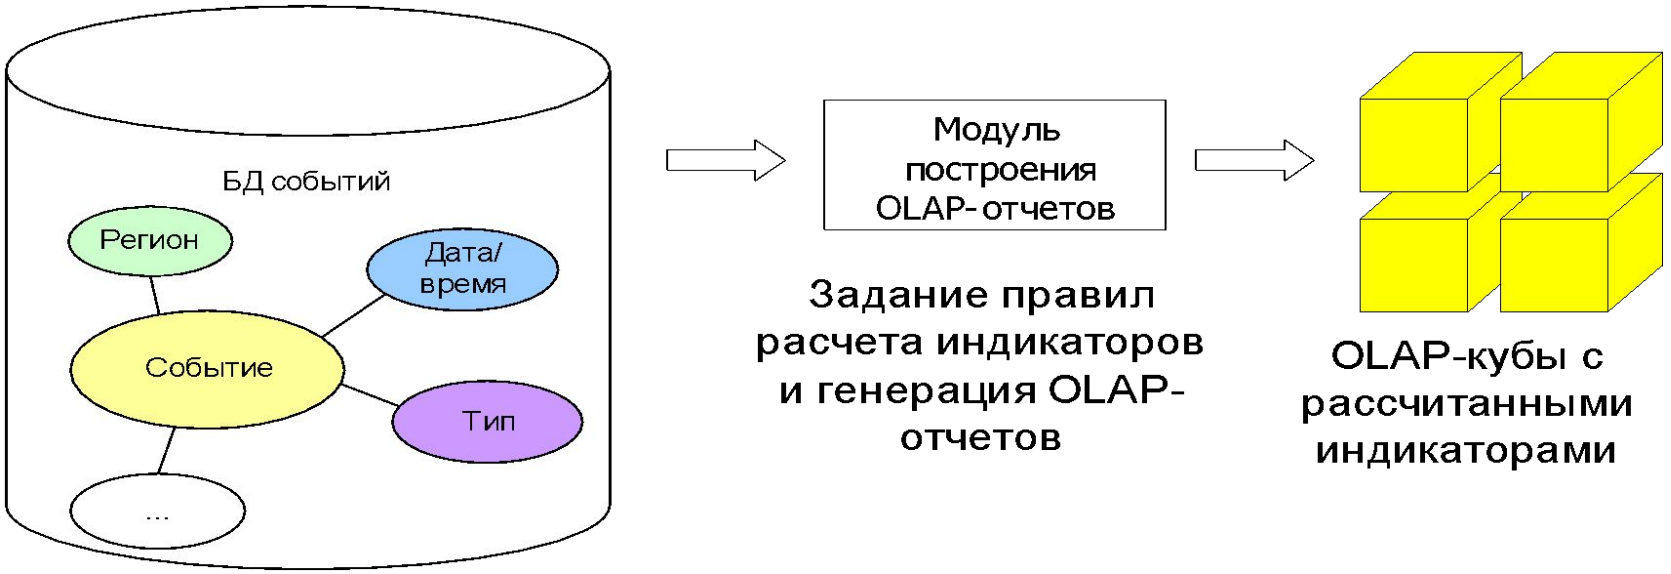

Выявление аномалий в значениях индикаторов

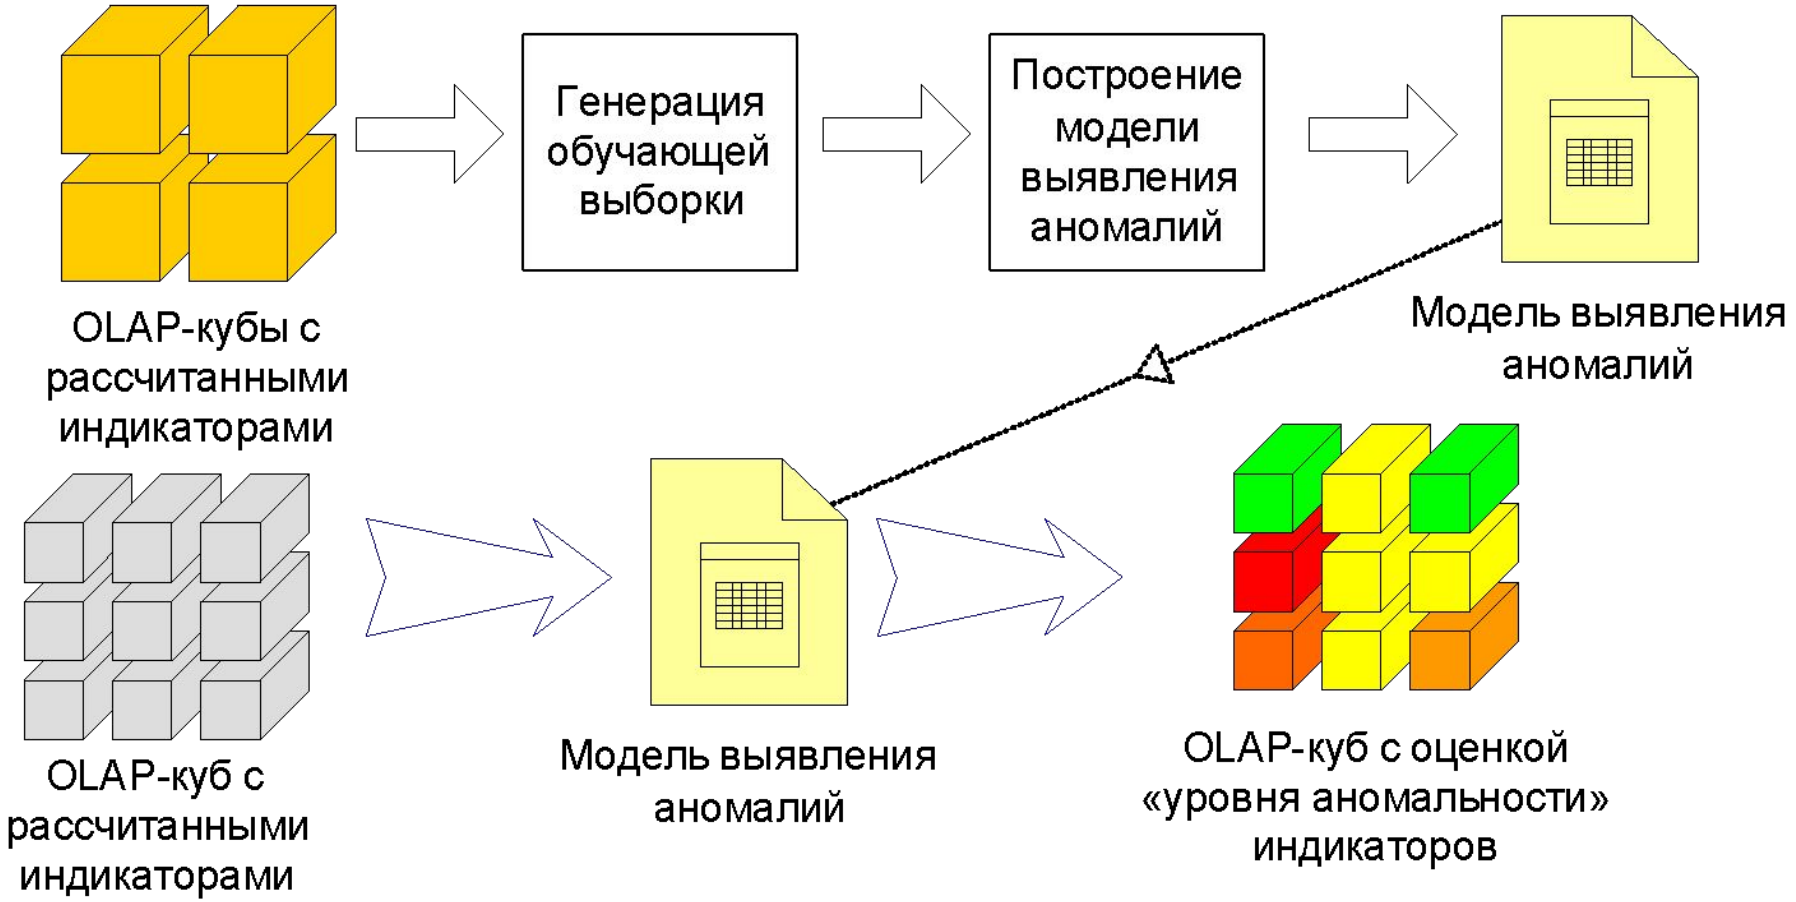

Определение тенденций и прогнозирование значений индикаторов

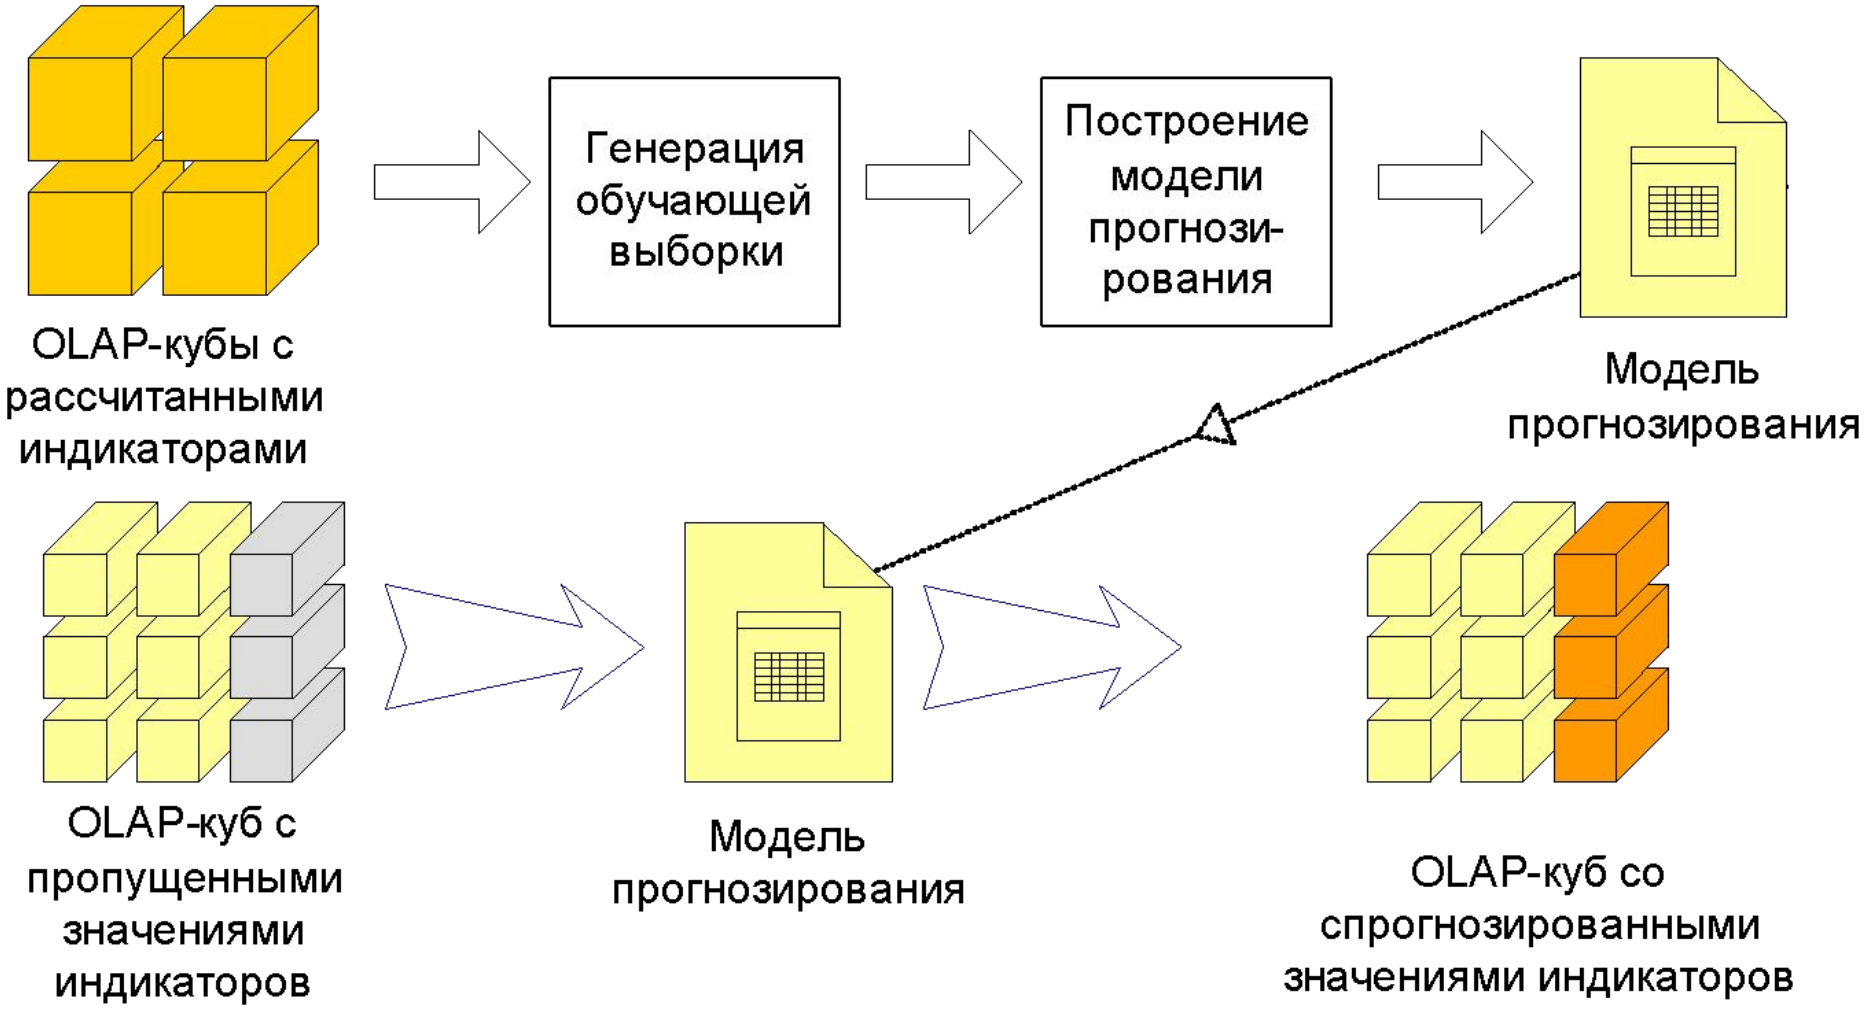

Текущие результаты

- Проектирование и создание рабочего места аналитика ситуационного центра мониторинга и анализа ситуаций:
  - Просмотр ситуации по срезам OLAP-куба в виде сводной таблицы, диаграммы или отображения на карте
  - Просмотр результатов выявления аномалий
  - Просмотр результатов прогнозирования
- Разработка и реализация специальных ИАД алгоритмов поиска аномалий и прогнозирования с учетом специфики данных – срезы OLAP куба.

Спасибо за внимание!
и
Вопросы?

д.ф.-м.н. И.В.Машечкин (mash@cs.msu.su),
к.ф.-м.н. М.И. Петровский (michael@cs.msu.su)

лаборатория «Технологий программирования»
ВМиК МГУ им. М.В. Ломоносова