

Глава 0. Введение. Общие сведения об интеллектуальном анализе данных

к.ф.-м.н. А.И. Майсурадзе
кафедра математических методов прогнозирования

ноябрь 2008

Оглавление лекции

- 1 Понятие об ИАД
- 2 Фундаментальные задачи ИАД
- 3 Различные виды исходных данных
- 4 Фундаментальные задачи ИАД (продолжение)
- 5 Исторический обзор развития ИАД
- 6 Технологии

Три направления решения интеллектуальных задач

Интеллектуальная задача

Задача обработки информации, возникающая в плохо формализованной прикладной области. Адекватные математические модели реальных объектов отсутствуют.

- Строгое математическое моделирование прикладной области
Отдельные успехи: Нобелевская премия акад. Канторовича.
Обычно создание адекватной модели невозможно.
- Моделирование процесса мышления
Человек справляется — пытаемся моделировать его способ решения. Перцептроны. Экспертные системы.
- Реализуем процесс преобразования информации
Несмотря на отсутствие модели того, как решает человек, несмотря на отсутствие адекватной математической модели реальной ситуации, опираясь на обычный здравый смысл.

Понятие об интеллектуальном анализе данных

Основная идея

Моделирование данных, а не явлений.

- Физика — моделирование явления (пример классического моделирования)
Основной задачей физики является построение математической модели некоторой системы или явления. Модель позволяет прогнозировать развитие явления или управлять системой.
- ИАД — моделирование данных (неклассическое моделирование)
Если мы не можем создать физическую модель явления, можно попытаться моделировать данные.

Эвристические информационные модели

Определение

Эвристическая информационная модель — это модель, описывающая данные. Она не опирается на законы природы, хотя и может базироваться на некоторых разумных предположениях.

Формализация — параметрические семейства алгоритмов.

Эвристические информационные модели

Определение

Эвристическая информационная модель — это модель, описывающая данные. Она не опирается на законы природы, хотя и может базироваться на некоторых разумных предположениях.

Формализация — параметрические семейства алгоритмов.

- линейный классификатор
- байесовские модели
- нейронный сети
- метрические модели
 - ближайшие соседи
 - парзеновские окна
 - потенциальные функции
- логические модели
 - решающие списки
 - решающие деревья
 - тестовый подход
- АВО
- ... многое другое ...

Фундаментальные задачи ИАД

При решении прикладных задач методами ИАД принято делить общую задачу на несколько подзадач (провести декомпозицию), каждая из которых уже известна и изучена.

Исторически сложился некоторый набор таких подзадач, на которые удобно проводить декомпозицию. Именно такие задачи называют фундаментальными задачами ИАД.

Задачи обучения с учителем

Supervised learning

- Задачи классификации
Надо получить алгоритм (классификатор), который каждый объект распознавания относит к некоторым классам из конечного, заранее заданного набора классов
- Задачи восстановления регрессии
Надо получить алгоритм (регрессию), который каждому объекту распознавания сопоставляет некоторое значение из бесконечного (непрерывного) множества
- Задачи обучения по прецедентам
Классификатор или регрессия настраиваются по заданному конечному набору прецедентов - объектов с заранее известными правильными ответами.

Задачи обучения с учителем

- Задачи прогнозирования
Обычно прогнозирование сводится к классификации или восстановлению регрессии, когда один из признаков определяет время.
- Задачи последовательного обучения
Прецеденты приходят последовательно во времени (один за другим). Алгоритм постоянно донастраивается.
- Архивирование, настройка модели источника
Символы на архивацию приходят последовательно один за другим.

Задачи обучения без учителя

Unsupervised learning

- Кластеризация (Сегментация)
Надо разбить все множество объектов на непересекающиеся подмножества (кластеры, сегменты), в которых объекты в каком-либо смысле похожи друг на друга.
- Нечеткая кластеризация, бикластеризация и т.д.
- Иерархическая кластеризация (Таксономия)
Надо построить дерево подмножеств, в котором каждый последующий слой является измельчением предыдущего.

Задачи с частичным обучением

Semisupervised learning

- Задачи с частичным обучением

Кроме прецедентной информации имеется информация о том, что некоторый набор объектов действительно существует и будет использован в ходе решения прикладной задачи. То есть для настройки алгоритма можно использовать прецедентную информацию и информацию о существовании данных объектов. Пример: база данных фотографий, ищем фотографии с лицами.

Выявление отклонений, детектирование

- Выявление ошибок в данных: так не может быть
Поступающая информация может содержать ошибки.
Источником возникновения ошибок может служить, например, неисправность измерительного прибора.
- Выявление нетипичного поведения: так раньше не было
Наша атомная электростанция раньше никогда не взрывалась.
Мы не знаем, как выглядит станция, собирающаяся взорваться, но систему мониторинга создать должны.
- Устранение отклонений из обучения (фильтрация)
Необходимо выявить те прецедентные данные, которые мешают качественно настроить модель.

Задачи восстановления пропусков

- Заполнение пропусков в прецедентах
Выбранный метод обучения модели требует, чтобы присутствовали все данные без пропусков.
- Заполнение пропусков в описаниях распознаваемых объектов
Настроенная модель требует, чтобы во вновь приходящих на обработку описаниях не было пропусков.

Решение обычно сводится к задачам классификации или восстановления регрессии.

Различные виды представления исходных данных

- **Признаковое описание объектов**
Фиксированный набор признаков. Каждому объекту ставится в соответствие вектор значений признаков.
- **Плоские таблицы, кросс-таблицы**
- **Описание эталонами**
Одна или несколько функций расстояния. Каждому объекту ставится в соответствие набор всех расстояний до всех заданных эталонов.
- **Метрическое описание пар объектов**
Фиксированный набор функций расстояния. Каждой паре объектов ставится в соответствие вектор значений расстояний.
- **Транзакционные данные, Формальные контексты**
Фиксировано множество элементов. Транзакция — конечное подмножество элементов.
- **Наличие элемента в транзакции — бинарный признак**

Фундаментальные задачи ИАД (продолжение)

Анализ наборов (не учитываем время транзакции)

Термин: анализ рыночной корзины

- Поиск популярных наборов
Популярный набор: чай и мёд часто покупают вместе
- Поиск ассоциативных правил
Ассоциативное правило: те, кто купил мёд, часто покупают чай

Анализ последовательностей (учитываем время)

- Поиск последовательных правил
Последовательное правило: Если сегодня купил принтер, то через месяц купит картридж

Анализ формальных понятий — формализация описания понятия в виде пары (объём, содержание)

- Поиск формальных понятий
- Построение и анализ решёток понятий

Исторический обзор развития ИАД

- Решение отдельных задач, методы под конкретные задачи. Первый этап начался в конце 50-х годов. Для конкретных прикладных задач инженерами разрабатывались отдельные алгоритмы распознавания.
- Появление моделей (обобщение методов, отбор успешных методов). Оформление (параметрических) семейств алгоритмов. Место моделей прикладных областей заняли семейства алгоритмов, которые можно считать моделями процессов преобразования.
- Коллективы алгоритмов. Начались попытки совместно использовать несколько моделей для решения одной задачи.
- Операции над алгоритмами, алгебры алгоритмов. Предпосылкой для возникновения алгебраического подхода послужило внутреннее противоречие, присущее самой идее использования заранее фиксированных параметрических семейств алгоритмов.

Технологические спутники ИАД

- Базы данных (Databases)
- Консолидация данных
- Хранилища данных (Warehouses)

- Аналитическая обработка (OLAP, on-line analytical processing)
- Системы отчетности (Reporting systems)

- Интеллектуальный анализ данных (Data Mining, Knowledge Discovery, Machine Learning)

Технологические спутники ИАД

- Сбор данных
- Проверка гипотез
- Генерация гипотез

Заключение

Ваши вопросы?