

清华大学数据库技术与应用

实用机器学习 II

授课教师：计算机系王健楠

授课学期：2026年（春季）



清华大学
Tsinghua University

01

异常检测

02

自动机器学习

- AutoML 动机与概述
- 自动特征生成
- Featuretools

03

可解释机器学习

AutoML 的动机

1. 机器学习非常成功!

2. 但构建一个ML Pipeline需要:

- 具有长期经验的领域专家
- 专业的数据预处理
- 领域驱动的有意义的特征工程
- 选择正确的模型
- 超参数调优
-

H2O Driverless AI 演示

思考问题:

- AutoML 软件会取代数据科学家吗?
- 作为数据科学家, 如何看待 AutoML?

◆ AI Overview

H2O.ai's revenue reached approximately **\$75 million in 2024**, up from \$67.8 million in 2023. The Mountain View-based AI company has shown consistent growth, specializing in open-source machine learning and AutoML, with a focus on enterprise AI adoption, serving over 20,000 organizations. [GetLatka +4](#)

Key revenue and company figures include:

- **2024 Revenue:** \$75M
- **2023 Revenue:** \$67.8M
- **Growth:** ~10.65% year-over-year from 2023 to 2024
- **Valuation:** The company reached a \$1.7B valuation following a Series E round in November 2021
- **Total Funding:** H2O.ai has raised over \$250M from investors, including NVIDIA, Goldman Sachs, and Wells Fargo [GetLatka +3](#)

H2O.ai serves a significant portion of the Fortune 500, focusing on automating data science processes. [H2O.ai +1](#)

演示视频: <https://www.youtube.com/watch?v=ZqCoFp3-rGc>

AutoML 的愿景

对非专家:

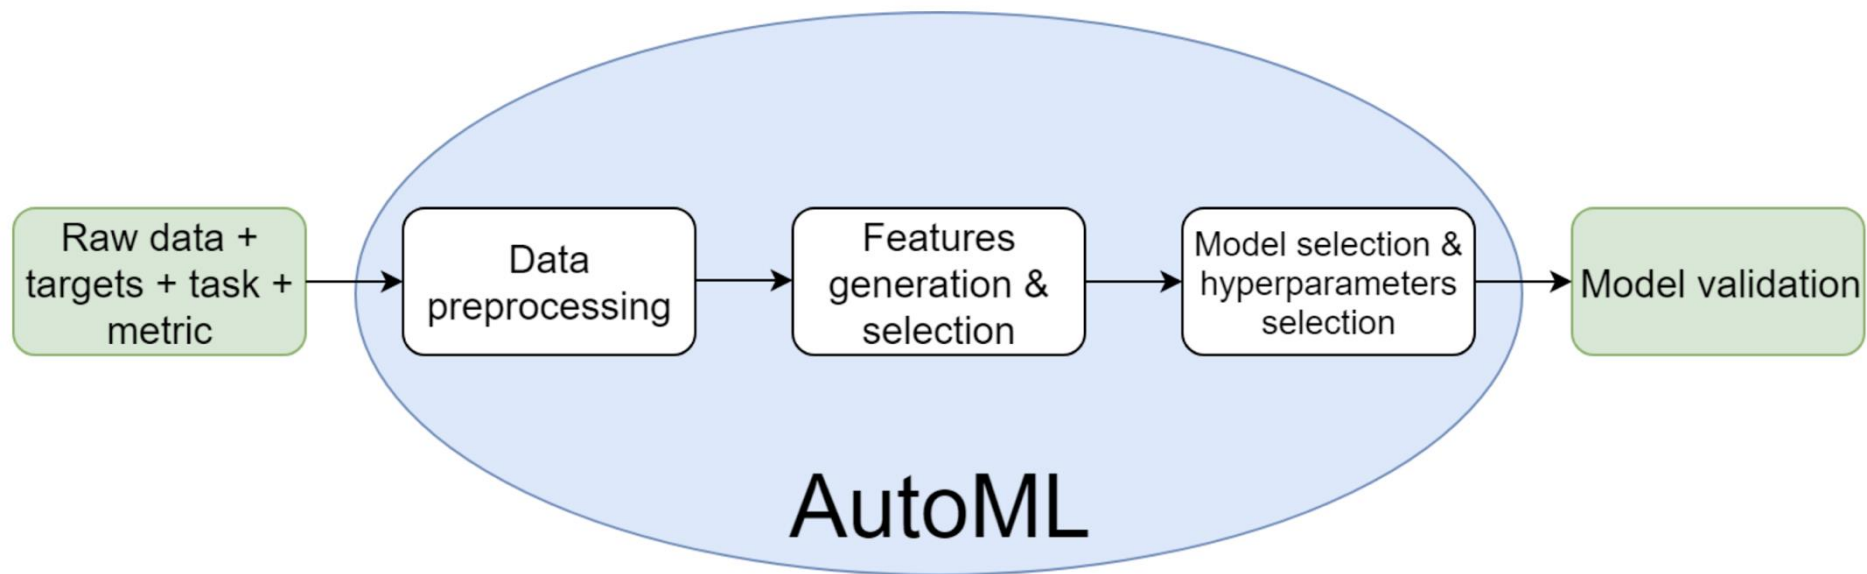
- AutoML 使非专家也能使用机器学习模型和技术
- 无需先成为该领域的专家

对数据科学家:

- AutoML 旨在增强 (augment) 而非自动化 (automate)
- 数据科学团队的工作和工作实践

什么是 AutoML?

自动化将机器学习应用于实际问题的过程



AutoML 内容概览

- **自动特征生成**
- 自动特征选择（前面已介绍）
- 自动超参数调优（前面已介绍）

自动特征生成的动机

- 模型性能高度依赖数据集中特征的质量
- 领域专家生成足够有用的特征非常耗时



特征生成方法

一元算子（作用于单个特征）：

- 离散化数值特征
- 日期的规则展开
- 数学算子（如 Log 函数）

高阶算子（作用于2+个特征）：

- 基本算术运算（如 +, -, ×, ÷）
- 分组聚合（如 GroupByThenAvg, GroupByThenMax）

Featuretools

- 开源的自动特征工程库
- 专为跨多关系表的特征生成设计



Featuretools 核心概念

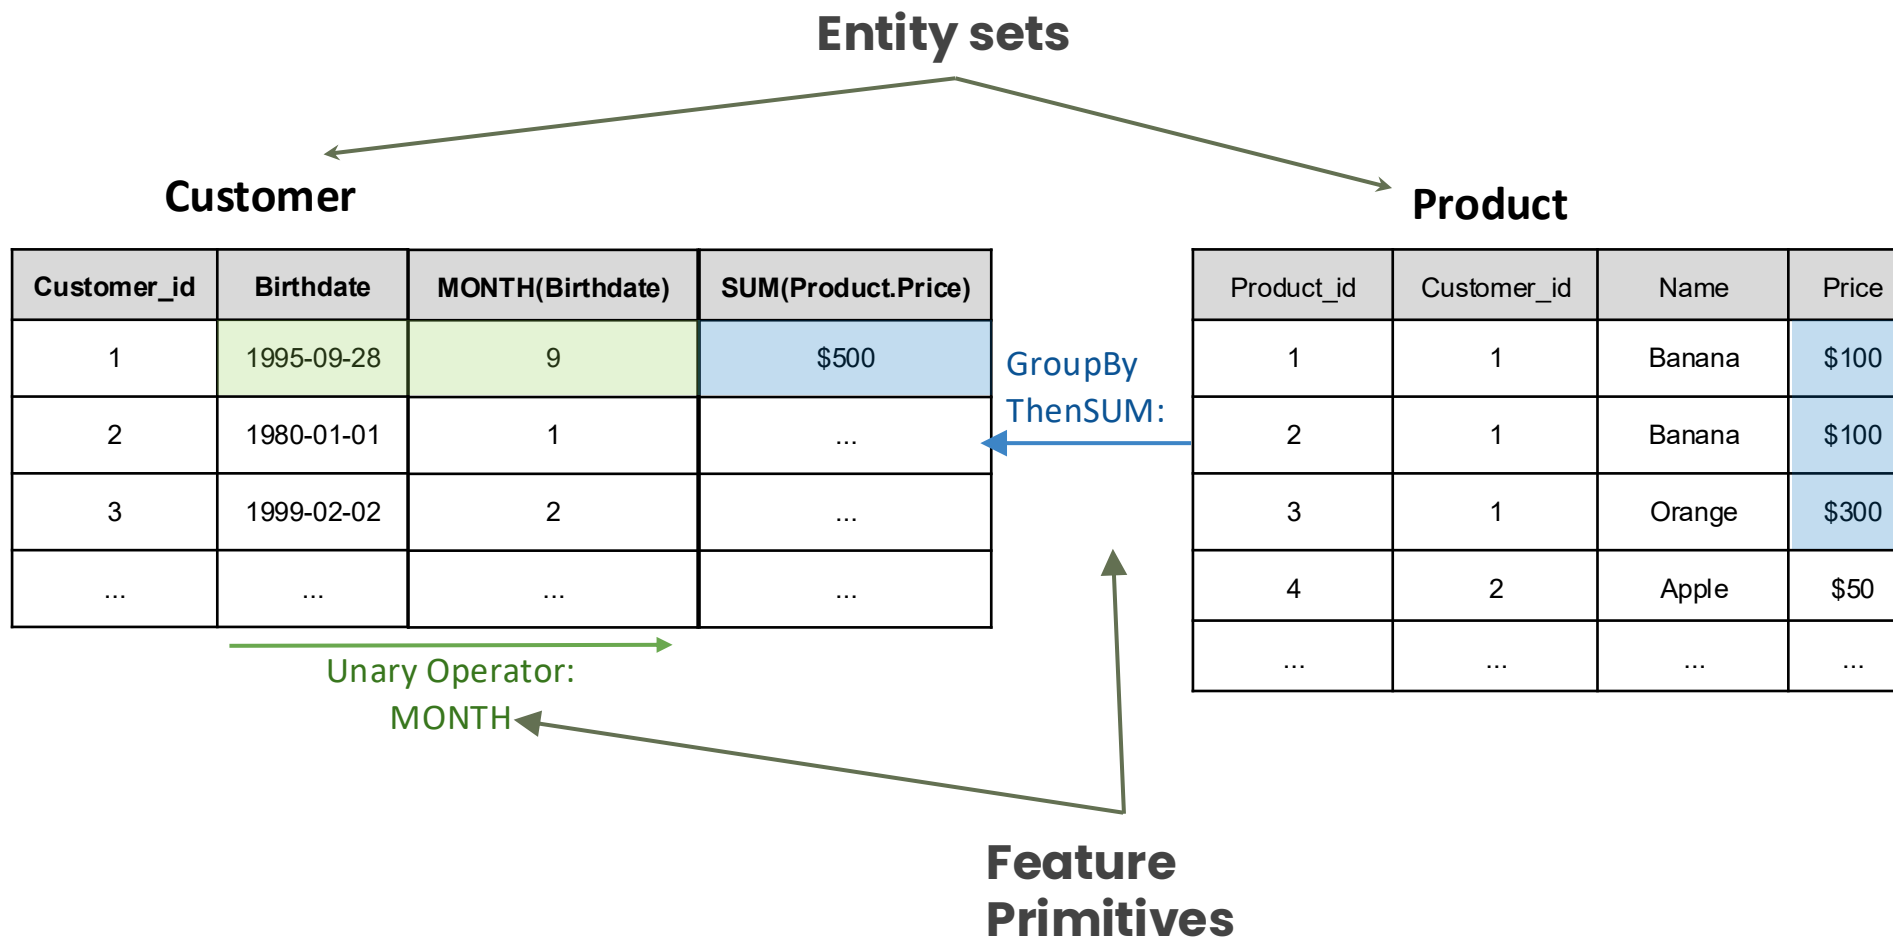
Entity: 实体表

EntitySet: 实体集合及其之间的关系

Feature Primitives (特征原语) :

- 一元算子: 如 MONTH
- 高阶算子: 如 GroupByThenSUM

Featuretools 示例



课程大纲

01

异常检测

02

自动机器学习


03

可解释机器学习


- 研究动机
- 全局视角
- 主流技术

更好的评估

你会选择哪个模型?




Bird: 99.0%



Bird: 99.9%


更好的评估

你会选择哪个模型?



A: Bird 99.0%

"因为它有翅膀和喙"



B: Bird 99.9%

"因为它是白色的且背景是蓝色"

法律合规

SR 11-7: Guidance on Model Risk Management



BOARD OF GOVERNORS
OF THE FEDERAL RESERVE SYSTEM
WASHINGTON, D.C. 20551

DIVISION OF BANKING
SUPERVISION AND REGULATION

SR 11-7
April 4, 2011

TO THE OFFICER IN CHARGE OF SUPERVISION AND APPROPRIATE SUPERVISORY AND EXAMINATION
STAFF AT EACH FEDERAL RESERVE BANK

SUBJECT: Guidance on Model Risk Management



Art. 22 GDPR

**Automated individual decision-
making, including profiling**

课程大纲

01

异常检测

02

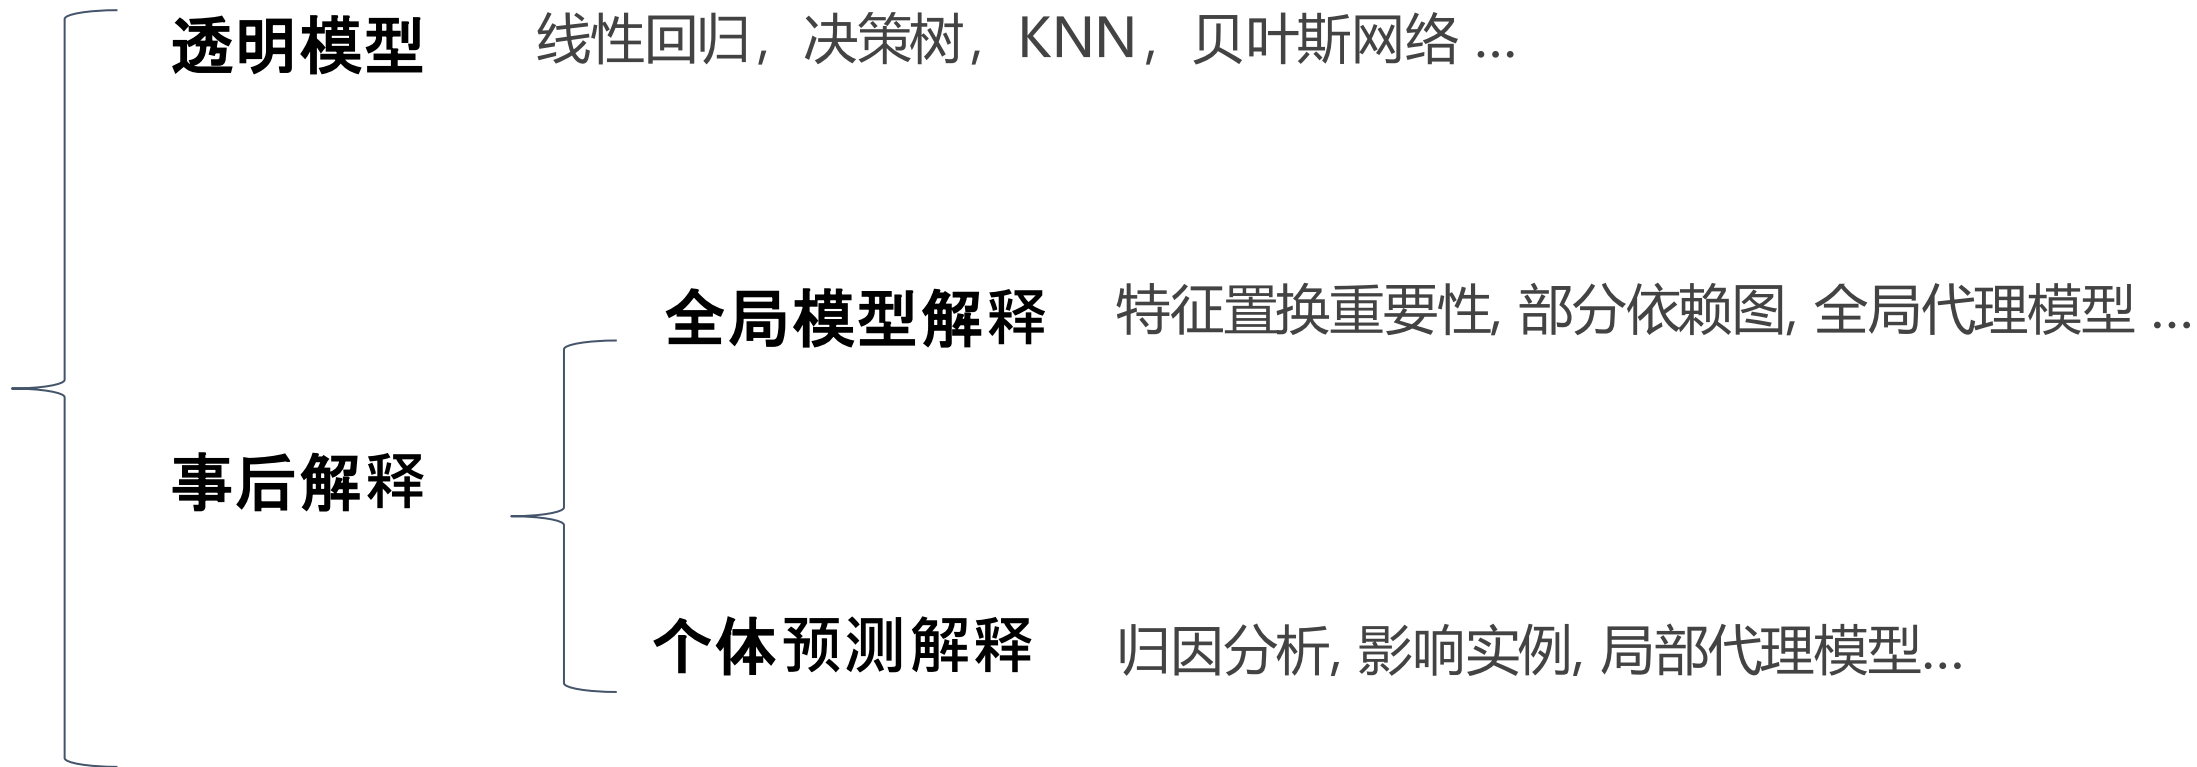
自动机器学习

03

可解释机器学习

- 研究动机
- ✓ **全局视角**
- 主流技术

分类体系



分类体系




线性回归

面积和距离如何影响房租？

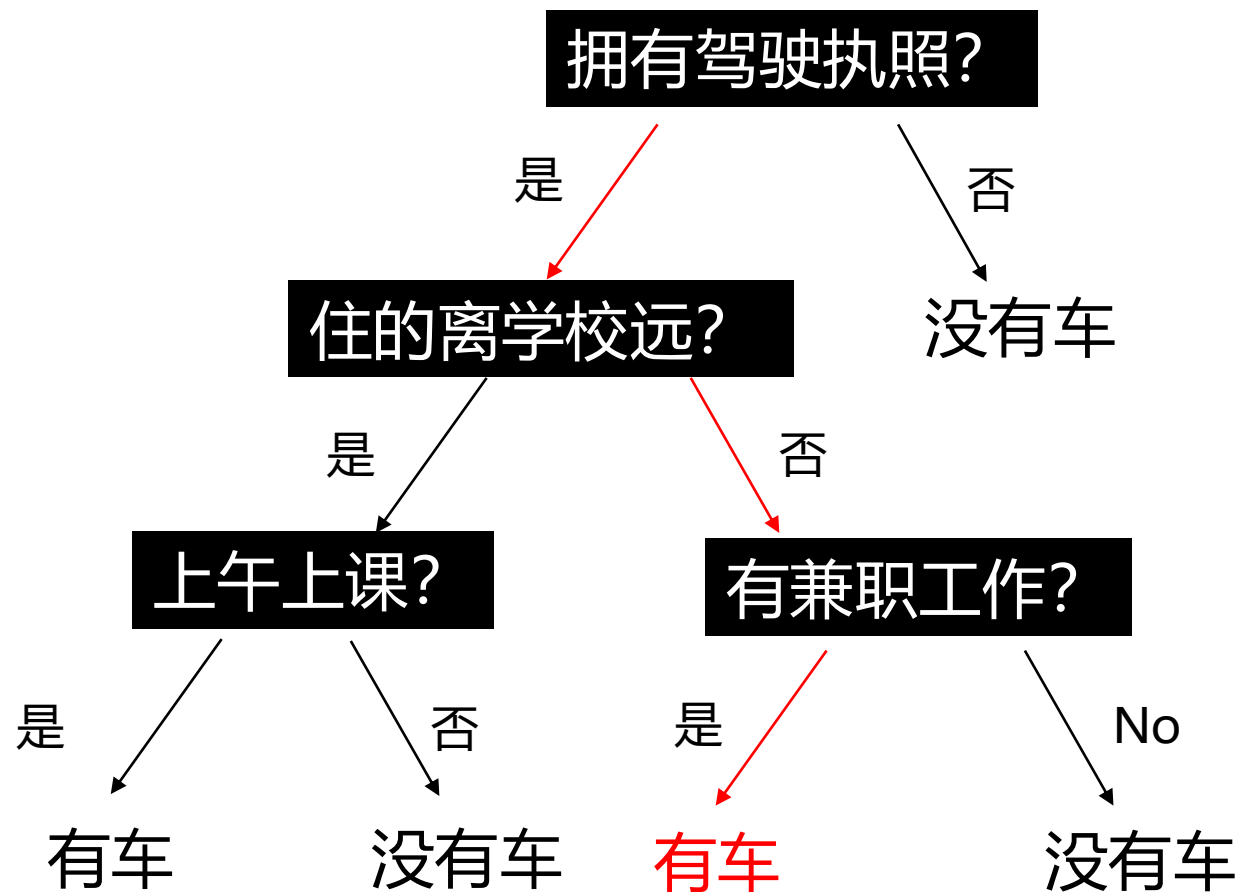
- 房租 (z)
- 面积 (x)
- 距离 (y)

$$z = 2.1x - 2.4y + 1800$$



决策树 (Decision Tree)

某学生是否拥有汽车?



模型为什么预测学生A有车?

- 沿着决策路径可以直接给出解释

分类体系



特征置换重要性 (Permutations)

核心思想:

- 通过计算打乱 (permuting) 某个特征后, 模型预测误差的增加量来衡量该特征的重要性

ID	到学校的距离	洗手间个数	面积	最近的公交站	...
1	5.0km	1	670 ft^2	0.30km	...
2	8.2km	2	920 ft^2	0.12km	...
3	2.3km	2	880 ft^2	1.20km	...
...
9999	10km	1	680 ft^2	0.05km	...
10000	7.8km	1	730 ft^2	0.23km	...



特征置换重要性 (Permutations)

输入：训练好的模型 + 带标注的评估数据集

输出：每个特征的相对重要性

方法：

1. 在原始数据集上应用模型，得到估计误差 E
2. 对每个特征：
 - 打乱该特征值，重新应用模型得到新误差 E'
 - 特征重要性 = $E' - E$ 或 E' / E



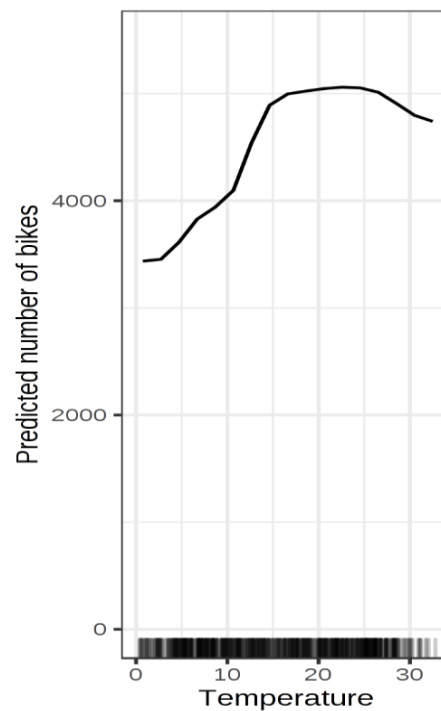
部分依赖图

核心思想:

- 展示一个或两个特征对机器学习模型预测结果的边际效应



ID	Temperature	Humidity	Wind Speed	Rental#
1	20	30	20	3000
2	25	35	10	2500
3	22	25	15	3300
..



部分依赖图 (PDP) 示例

通过PDP可以直观看到：

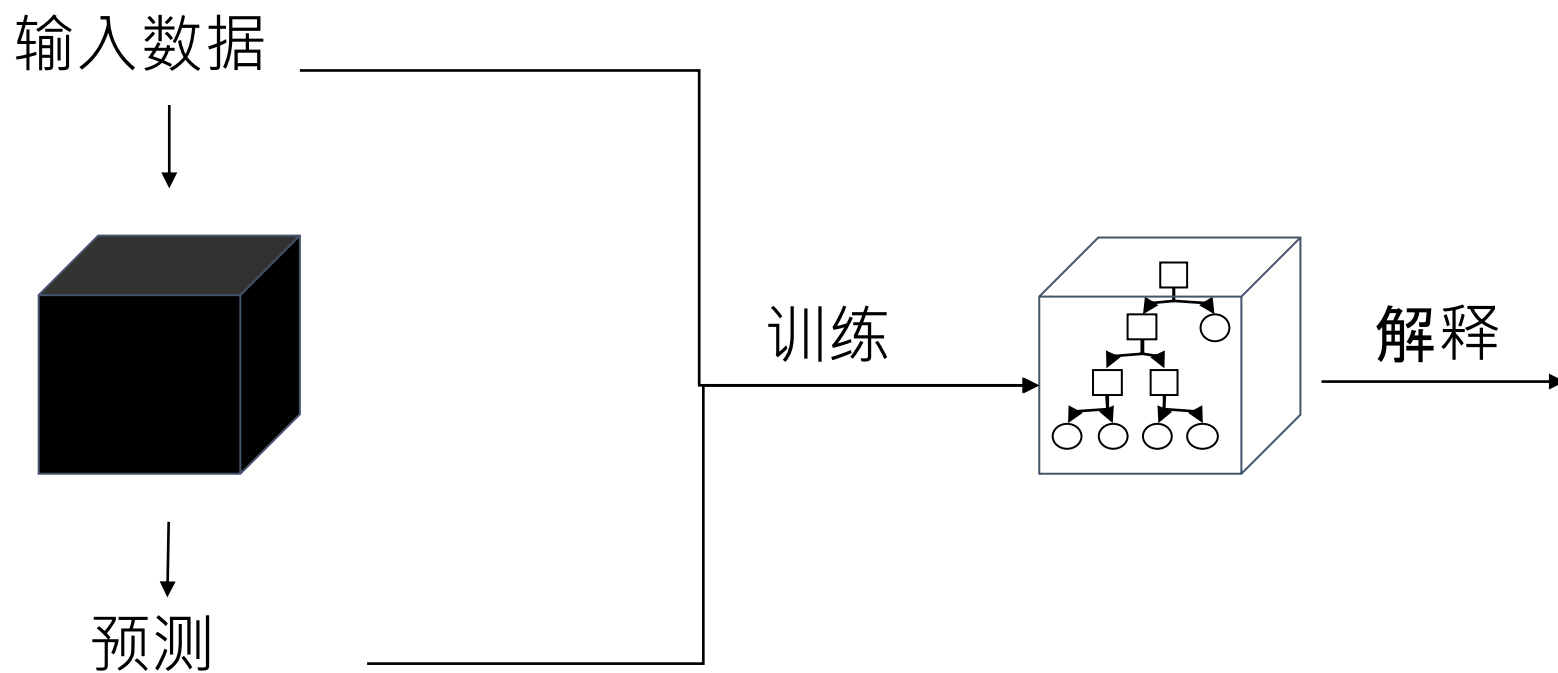
- 某个特征值的变化如何影响预测输出
- 特征与目标变量之间的非线性关系

局限性：假设特征之间相互独立

全局代理模型

核心思想:

- 训练一个透明模型来近似黑盒模型的预测



全局代理模型

步骤:

1. 用黑盒模型对数据进行预测
2. 用透明模型（如决策树）拟合黑盒模型的预测
3. 解释透明模型 → 近似理解黑盒模型

注意:

- 代理模型的保真度很重要
- 代理模型越简单越好解释，但可能不够准确

分类体系



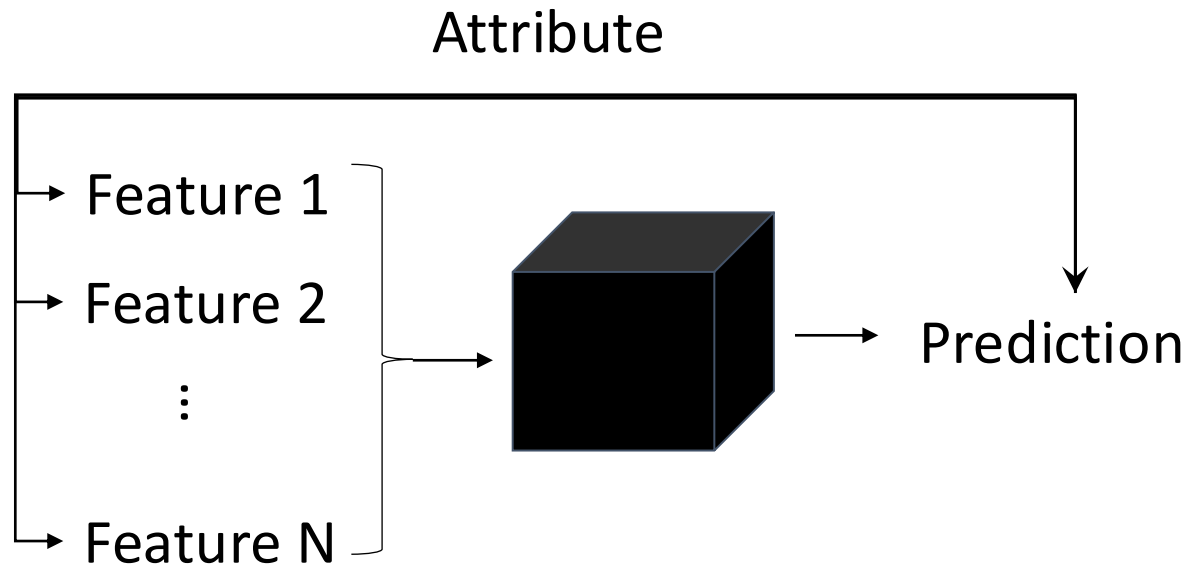
归因分析 (Attribution)

核心思想:

- 将模型对某个样本的预测归因到其各个输入特征


方法:

- 消融法
- Shapley 值
-



归因分析：消融法 (Ablation)

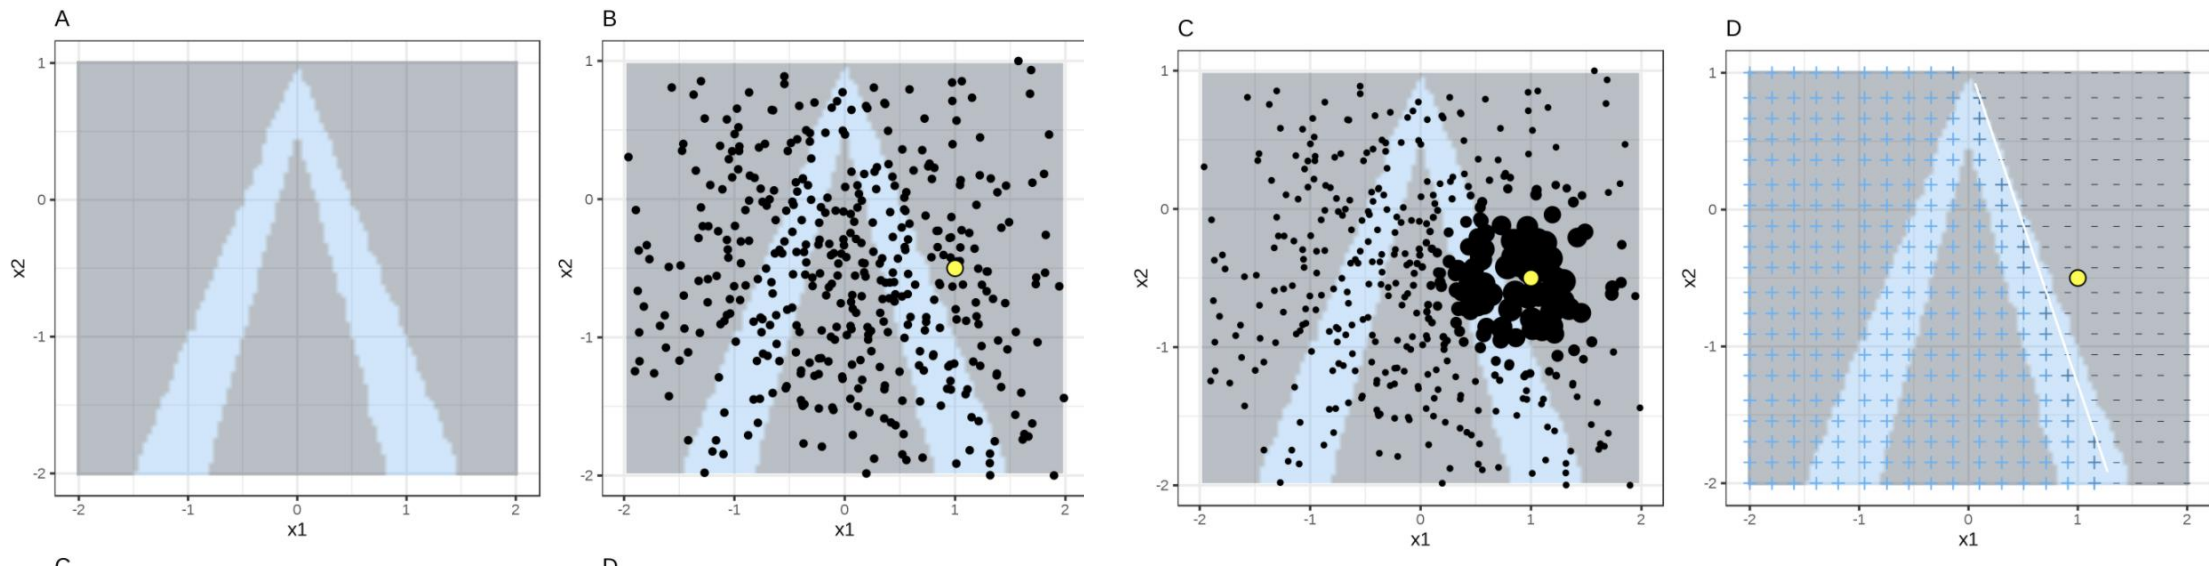
- 逐个遮挡/移除特征，将预测变化归因给该特征



局部代理模型 (LIME)

核心思想:


- 向机器学习模型输入数据的不同变体, 观察预测如何变化



影响力实例 (Influential Instances)

核心思想:

- 通过识别对模型预测影响最大的训练实例来调试机器学习模型
- 当从训练数据中删除某个实例后模型预测显著变化时, 该实例具有影响力



可解释机器学习：总结



课程总结

第一部分：异常检测与机器学习实战

- 从问题到部署的完整ML解决方案设计流程
- 异常检测、聚类、特征工程、参数调优、模型部署

第二部分：自动化机器学习 (AutoML)

- 自动特征选择、超参数调优、特征生成
- 神经架构搜索 (NAS)

第三部分：可解释机器学习

- 透明模型 vs 事后解释
- 全局解释与个体预测解释方法

数据驱动 → 模型构建 → 自动化 → 可解释



清华大学数据库技术与应用

谢谢!

授课教师: 计算机系王健

授课学期: 2026年



清華大學
Tsinghua University