

人工智能介绍

忻斌健

日期: 2023.11.24 Date: 2023.11.24

目标:

- 人工智能，深度学习简介
- 在新能源汽车行业应用

01

深度学习理论简介

02

能源优化系统

03

电池安全状态检测



01




人工智能/深度学习



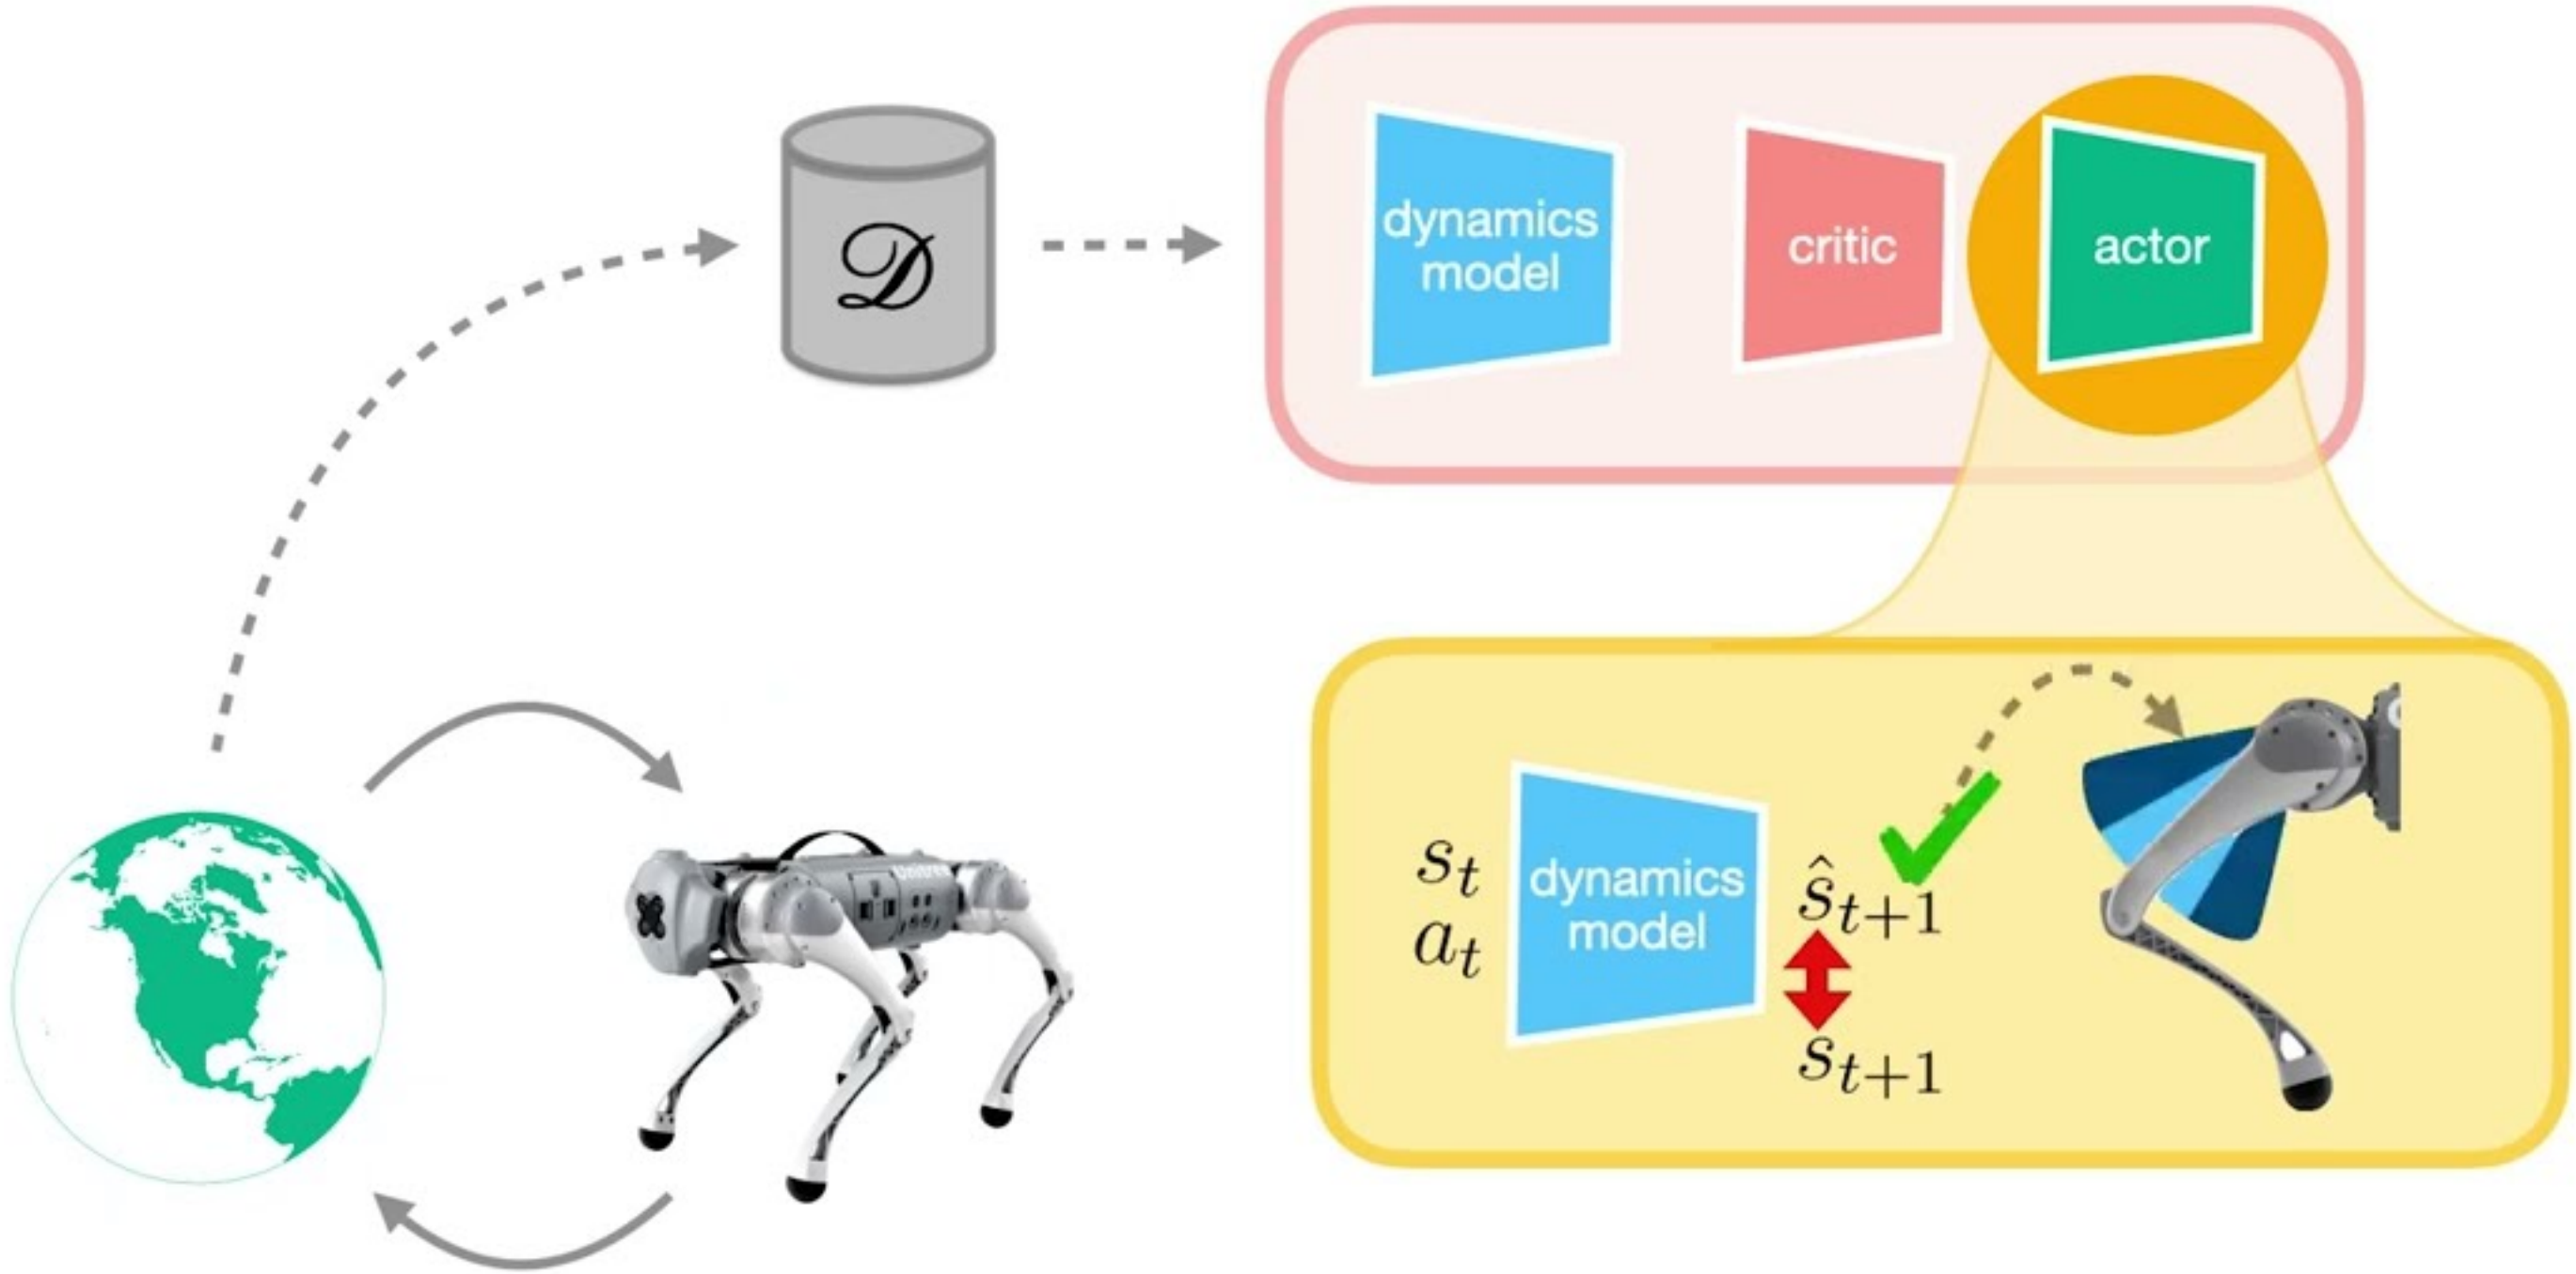
智能 (Intelligence)?

- 生物学：行为学， (inwards), 描述性 declarative, 归纳性, knowing-that
- 人工智能：数学，物理， (outwards), 工程化 procedural, 真正理解智能 knowing-how
 - Ghost in the machine (Gilbert Ryle 吉尔伯特·赖尔 1949): 二元论的谬误, 范畴错误 (精神和躯体的区分)
 - 把意识过程 (智能) 和物理过程割裂开
- "Can Digital Computers Think?" 1951 Turing





again relax the regularization until the new situation is also predictable



机器学习

机器可以学习

- 神经网络（前馈，卷积，并发，变形金刚，GPT）
- 梯度反向传播（Gradient Backpropagation）
- 规模化（Scaling Law）和浮现性能（Emerging capabilities）

为何学习（机器/万物）

- 普适的简单假设：
 - 动态系统，边界
 - 无需假设能动性（Agency）或者意志，愿望
 - 复杂性假设（Ruliad）和不可约计算性

- 机器如何学习
 - 优化神经网络（深度学习）
 - 网络架构
 - 全连接层（前馈网）
 - 卷积层（卷积网）
 - 注意力层（变形金刚网）
 - 稀疏拓朴层（图神经网络）
 - 优化
 - 构造损失(目标函数, 极大似然估计)
 - 梯度反向传播

- 机器如何学习

- 目标

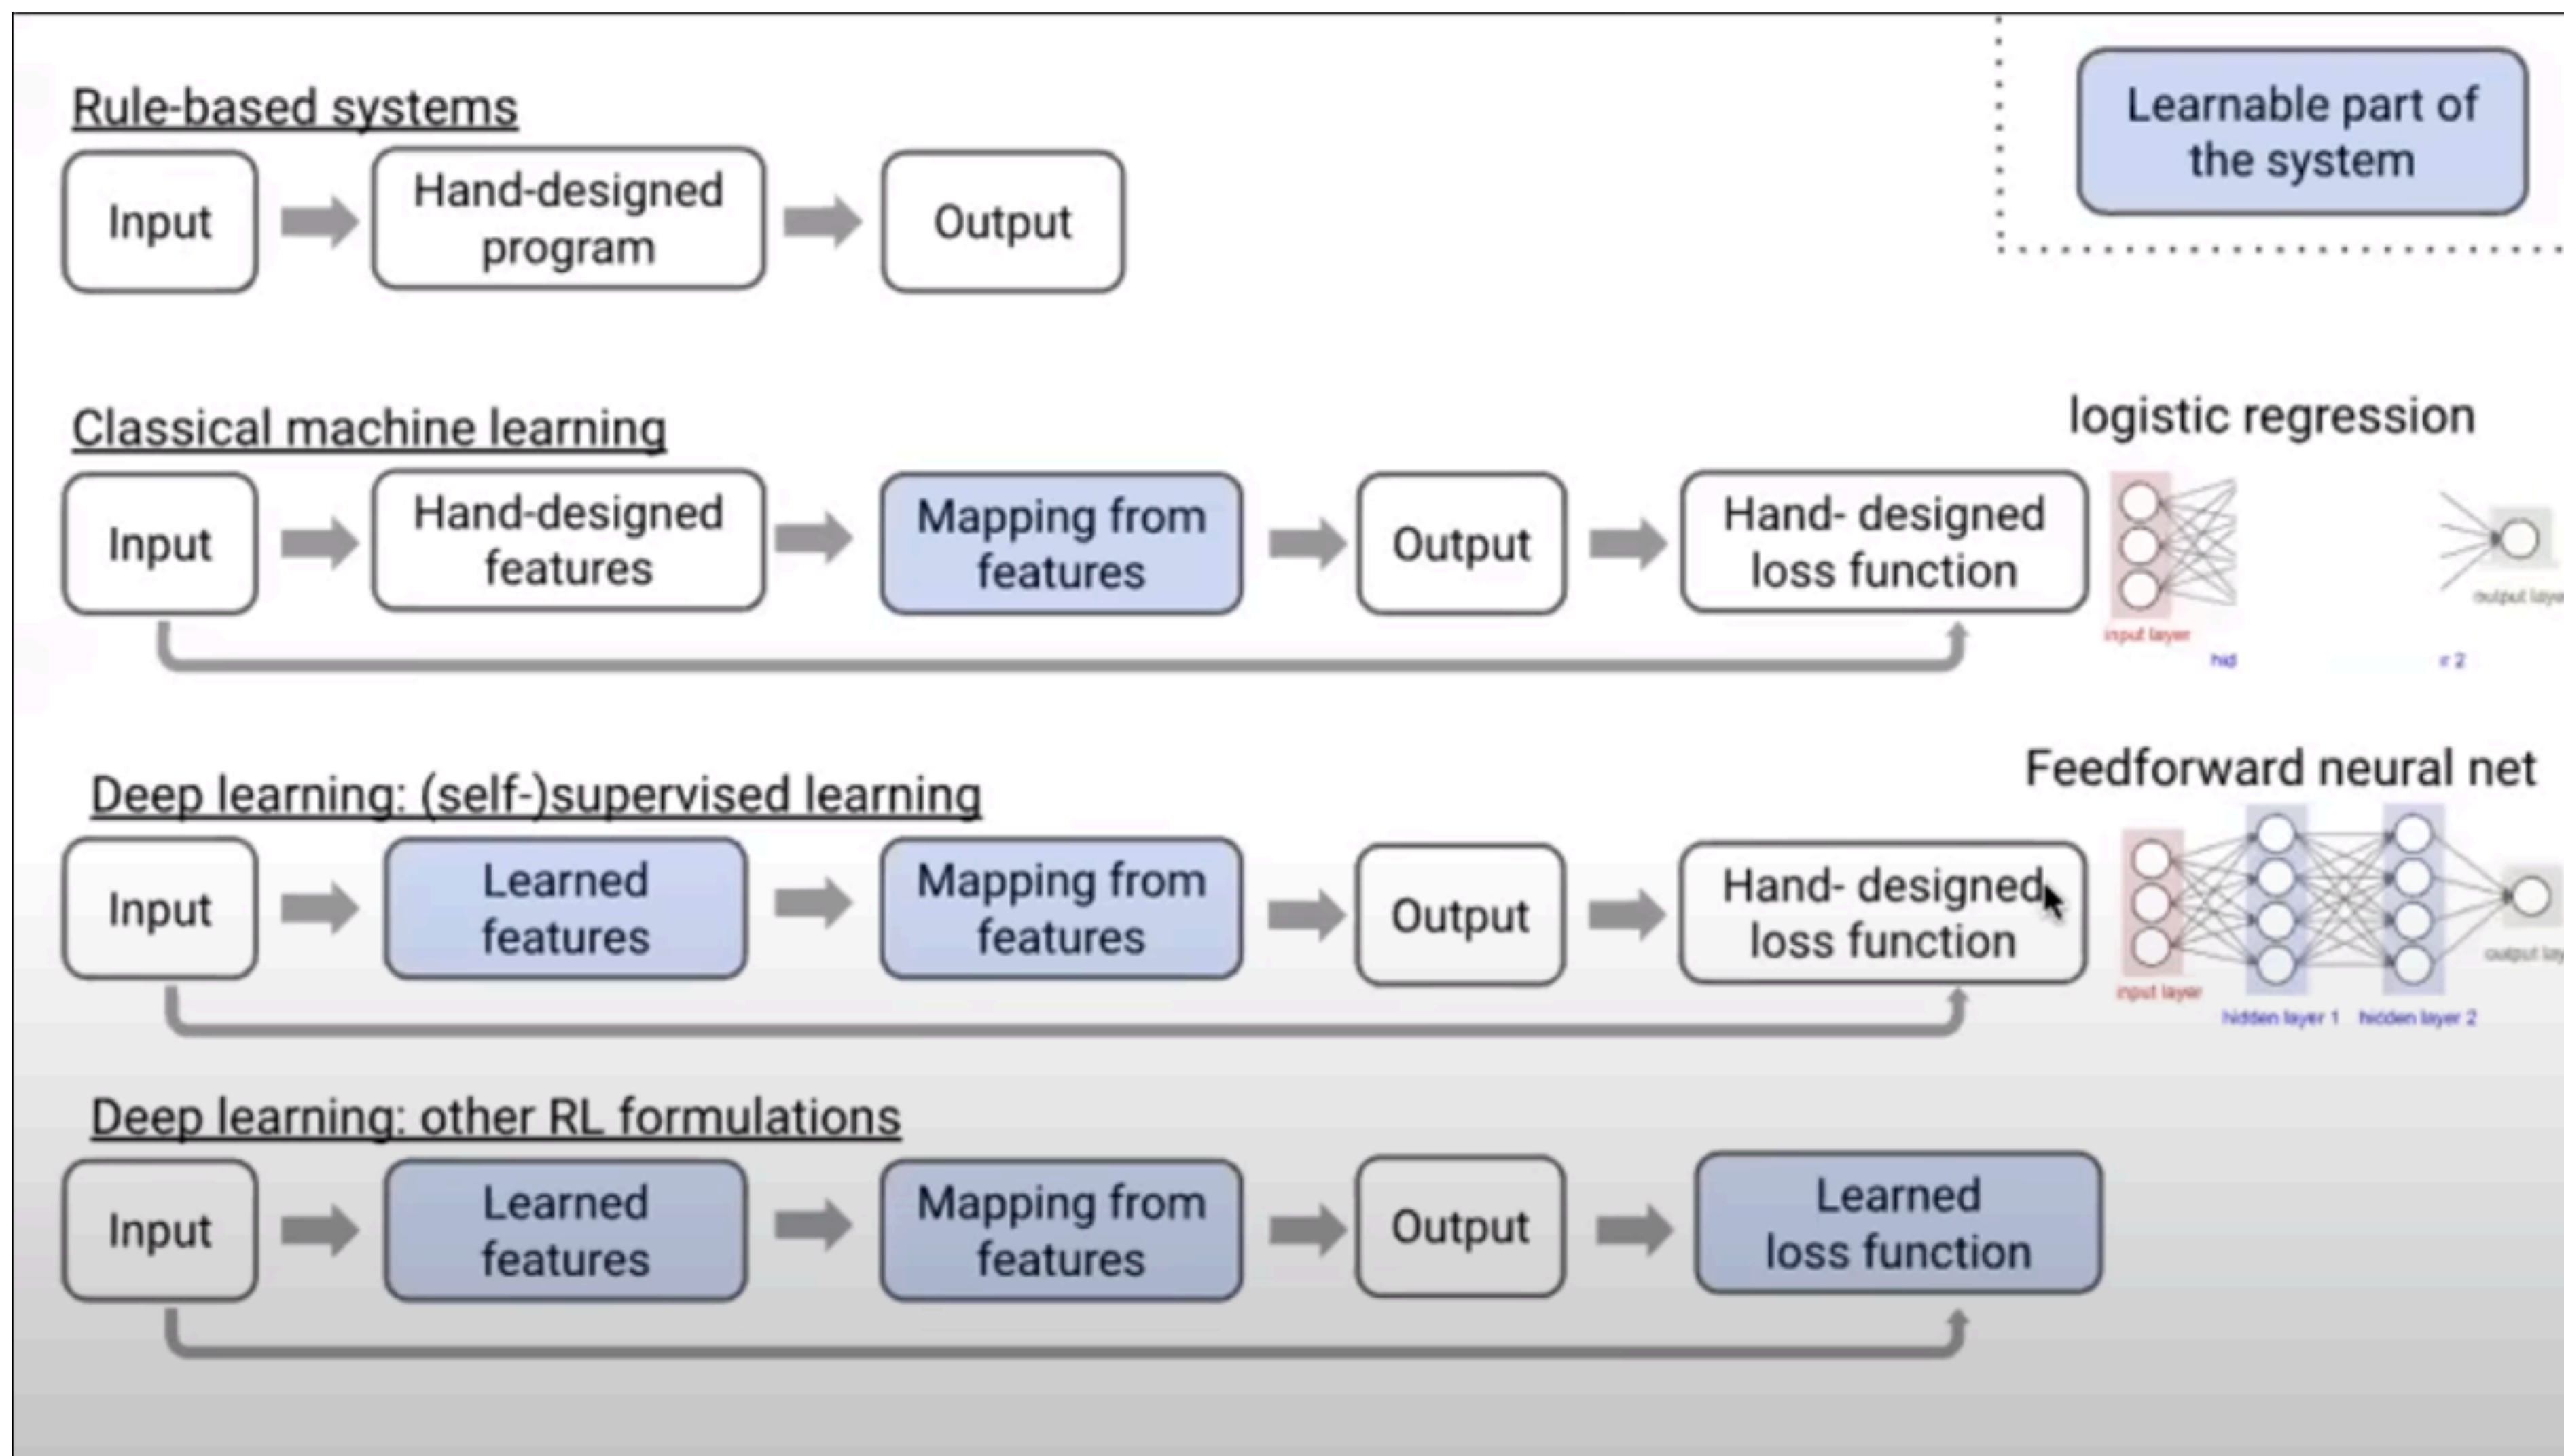
- 监督学习：极大似然估计
- 生成模型 Generative Model （动态随机过程，概率分布的变换）
 - 变分自编码 VAE
 - 对抗生成网络 GAN
 - 扩散模型 Diffusion Model 动态随机过程
- 柯尔莫哥洛夫复杂度(知识压缩作为目标)
- **主动推理（自由能量原则，动态平衡）**
 - 最大化目标：基于内在模型的置信精度+熵（最小化惊奇值 surprise）
 - 最大化的自变量：内在模型的参数

泛化能力



• 机器如何学习

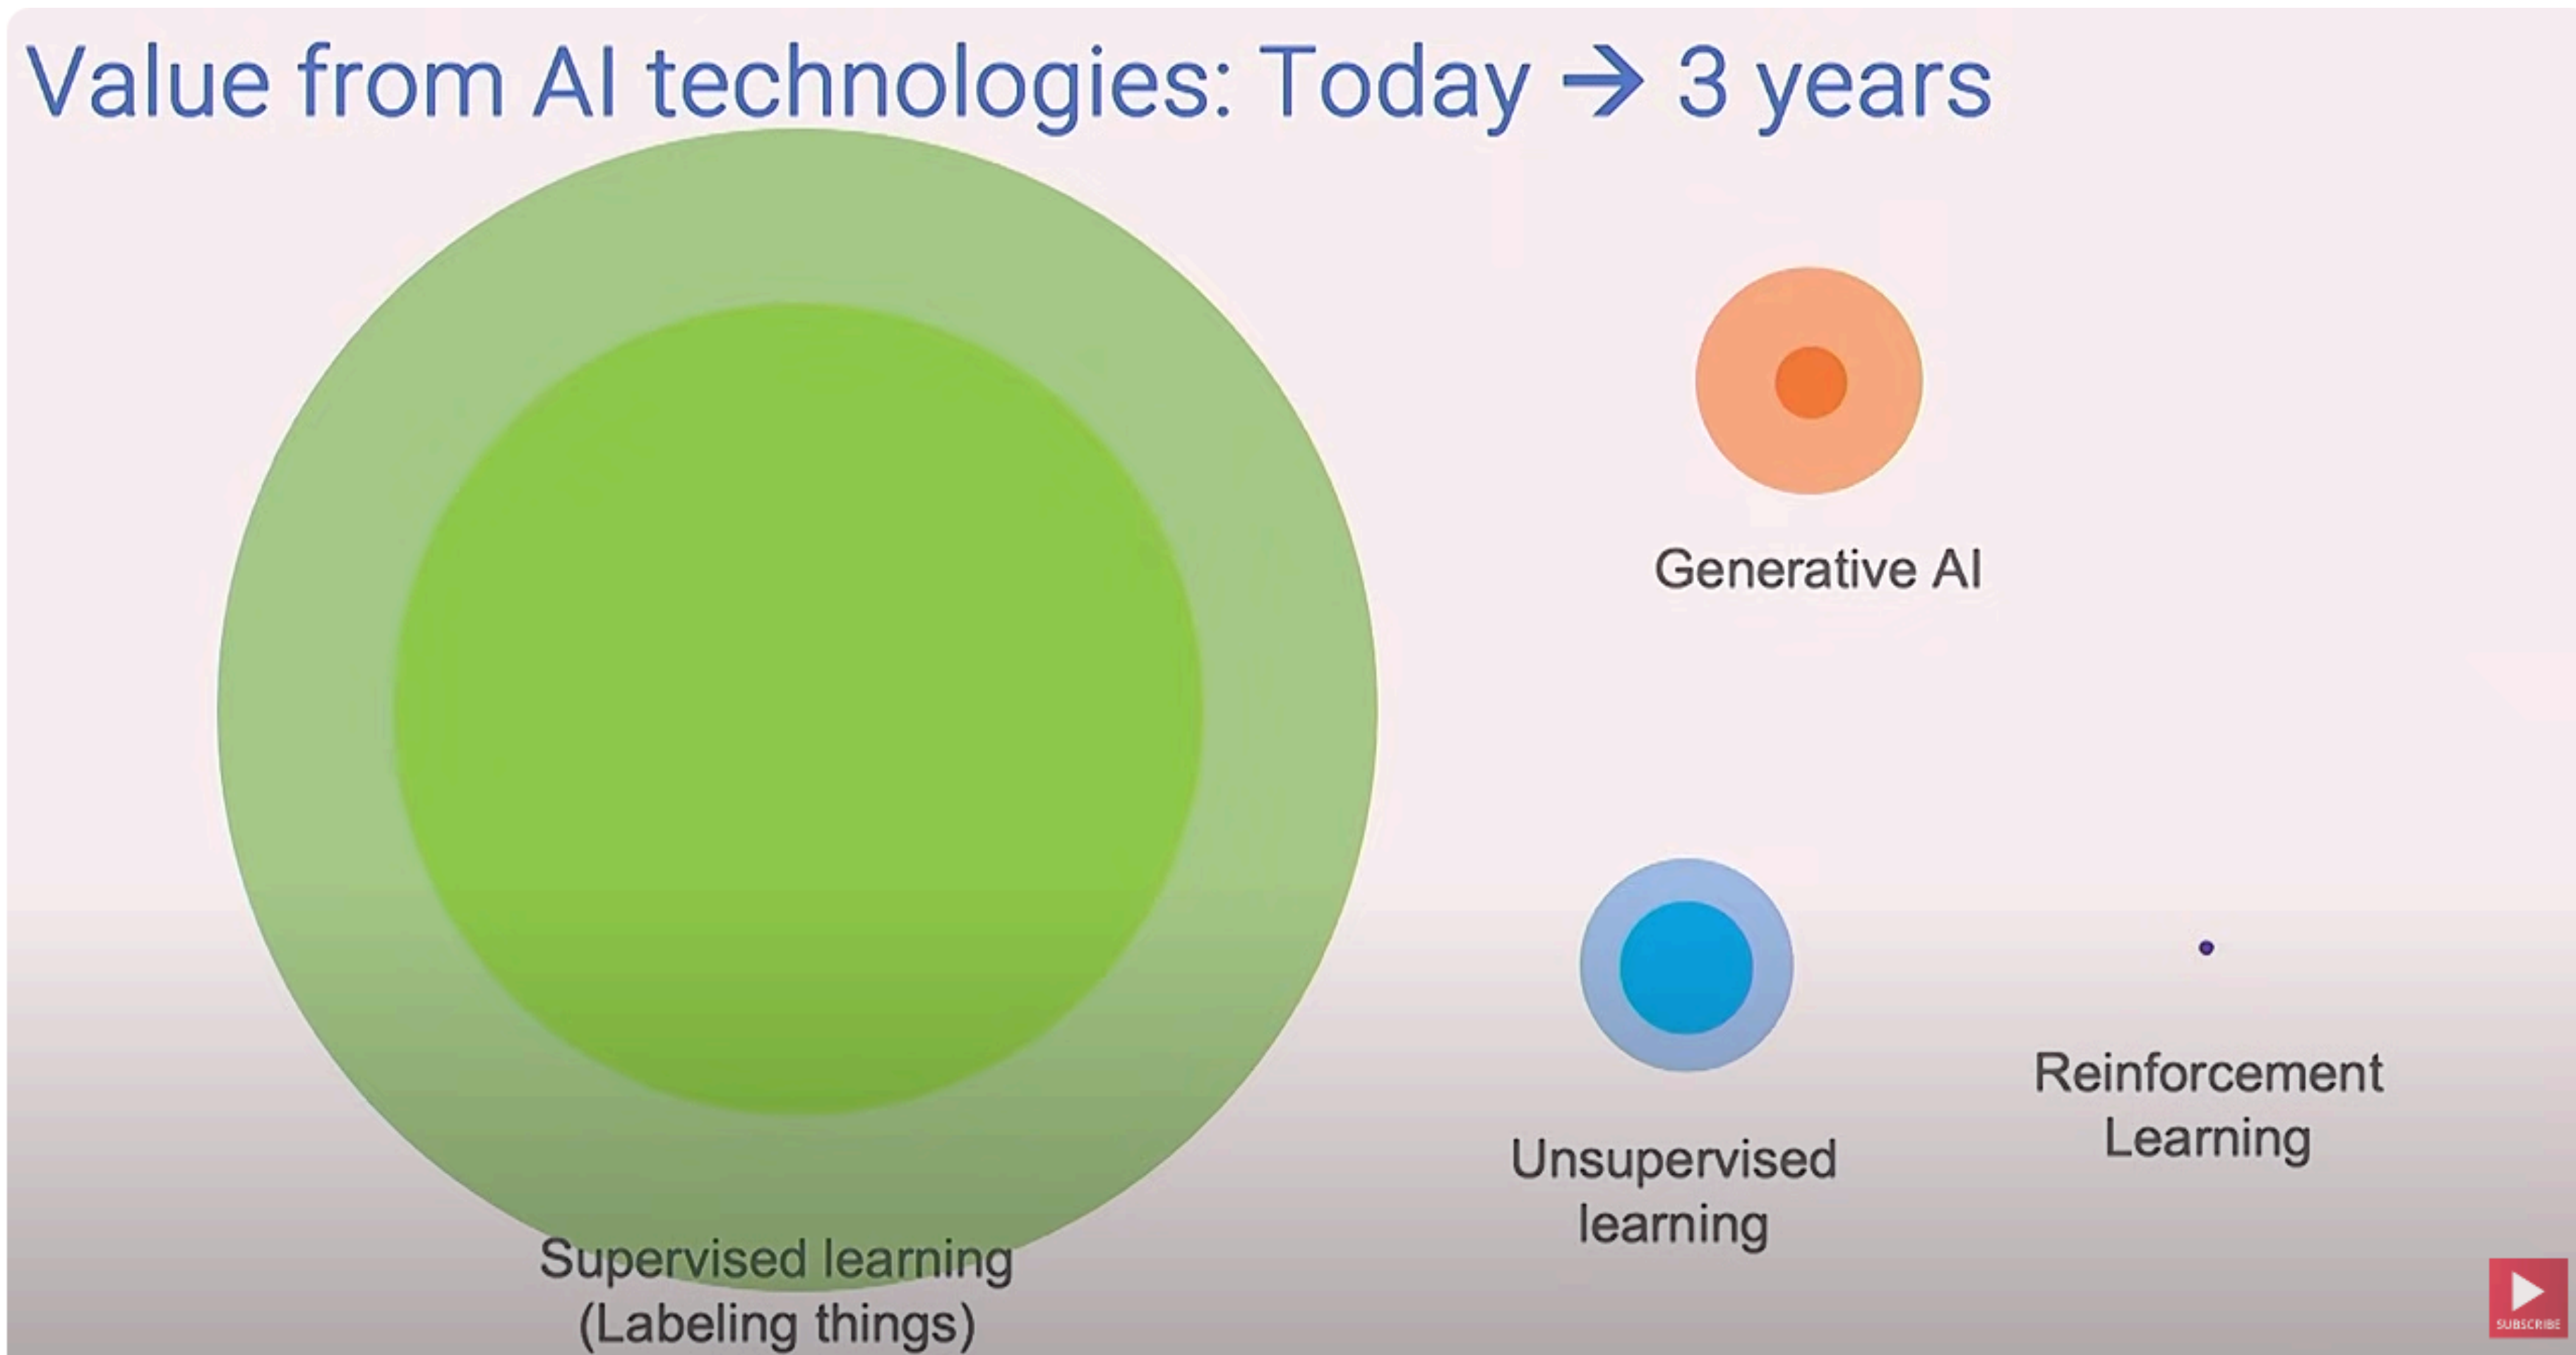
泛化能力



机器学习

机器如何学习

- 监督学习
- 半监督学习
- 自监督学习
- 目标函数



机器学习示例

线性回归用于房价预测

<https://www.geeksforgeeks.org/ml-linear-regression/>

[https://github.com/AshishJangra27/Machine-Learning-with-Python-GFG/blob/main/](https://github.com/AshishJangra27/Machine-Learning-with-Python-GFG/blob/main/Regression/1%20Linear%20Regression/Linear%20Regression%20from%20Scratch.ipynb)

[Regression/1%20Linear%20Regression/Linear%20Regression%20from%20Scratch.ipynb](https://github.com/AshishJangra27/Machine-Learning-with-Python-GFG/blob/main/Regression/1%20Linear%20Regression/Linear%20Regression%20from%20Scratch.ipynb)

智能 (Intelligence)?

- 创造力, 解决问题, 模式识别, 分类, 学习, 归纳, 演绎, 类比, 优化, 生存能力, 语言处理能力, 知识处理?
- 白板说 / 内在说
- 人工智能 (AI) : 目标驱动 (或优化某个效益函数: 生存)
- 自适应不同的工作环境 (AGI): 环境复杂度 (Deepmind, etc.)
- 数据重要性的争论
 - Mind over data (Judea Pearl)
 - Data over mind 【DeepMind (Rich Sutton); Google (Peter Norvig), ...】
 - 数据使用的效率

苦涩的教训 “The Bitter Lesson” Rich Sutton 2019.03.13

- **最有效的人工智能方法是最能利用计算资源的算法**
 - 语音识别，自然语言处理
 - 图像处理（卷积和特定空间变换的不变性）
 - 游戏（控制）
- **通用算法（搜索和学习）是最重要的算法**
- **人为规则强加给系统会限制系统性能**



深度学习是非常特殊的人工智能方法

- **专家系统（基于规则）是演绎（deduction）**
 - 是用已有的知识进行预测/解释；
 - 已有的知识从哪里来？内在还是从经验？
- **学习方法（Learning）是一种归纳（induction）**
 - 归纳的定义是从数据中寻找一种模式并用于预测
 - Solomonoff归纳原则：寻找最简洁的模式（奥卡姆剃刀原则）
 - 模式的表示方法：数学（代数，几何，概率），代码（程序）
 - 可计算宇宙
- **因果推断(Causal inference) 属于溯因推理(abduction)**

深度学习基本原理：神经网络参数的极大似然估计

- 目标识别（深度卷积网）

- 大数据：Imagenet 2009: 22000个类, 1400万样本

- Alexnet: 数据集 1000个类, 120万训练样本, 5万验证样本, 15万测试样本

- 深度神经网络：Alexnet

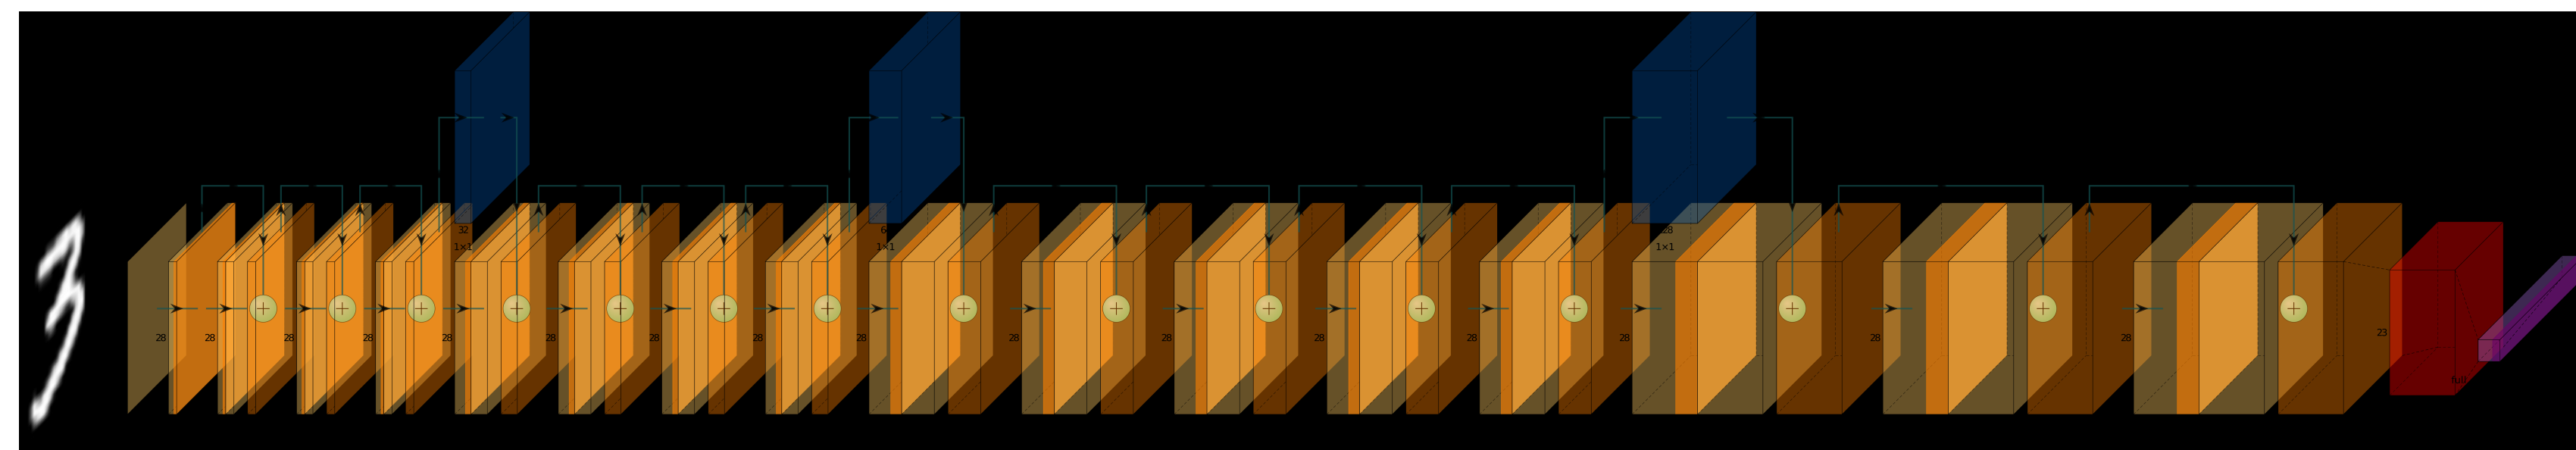

- 5个卷积层,3个全连接层

- 参数6200万个（正则化）

- 归纳偏差（先验知识/规则）


- <https://www.cs.ryerson.ca/~aharley/vis/conv>


- Resnet-50




深度强化学习:

- 通过与环境交互学习最优策略 (基于大数据)
- 积累经验 (缓存在状态/行动价值函数中)
- 可以是无模型或动态建模
- 可以是在线算法
- 动态调整策略





这些动物不存在!



- **生成模型：从文字到图片**
 - **Dall-E**
 - **Imagen**
 - **StableDiffusion**
 - **Parti**
- <https://huggingface.co/spaces/stabilityai/stable-diffusion>
 - The Bund of Shanghai after a severe drought. Tugs are stranded in the middle of the dried up riverbed.
 - Klimt's Kiss in the anime style.
 - A truck under a row of autumn maples with heavy maple leaves layer on the ground.
 - An astronaut riding a goat in a photorealistic style
 - robot insect legion invading Shanghai

愿景：

- 运用AI技术，特别是深度学习和强化学习，更准确预测和改善车辆运营的能效
- AI赋能的过程自动优化系统，改善运营和生产效率，增加安全性

领域：

- 车辆能源优化系统 (Vehicle Energy Optimization System VEOS)
- 电池银行 (Battery Bank)

任务：

- 通过调整电动力和智能驾驶系统的控制器参数改善电动车能效
- 预测动力电池工况和健康状态 (SOH)



02

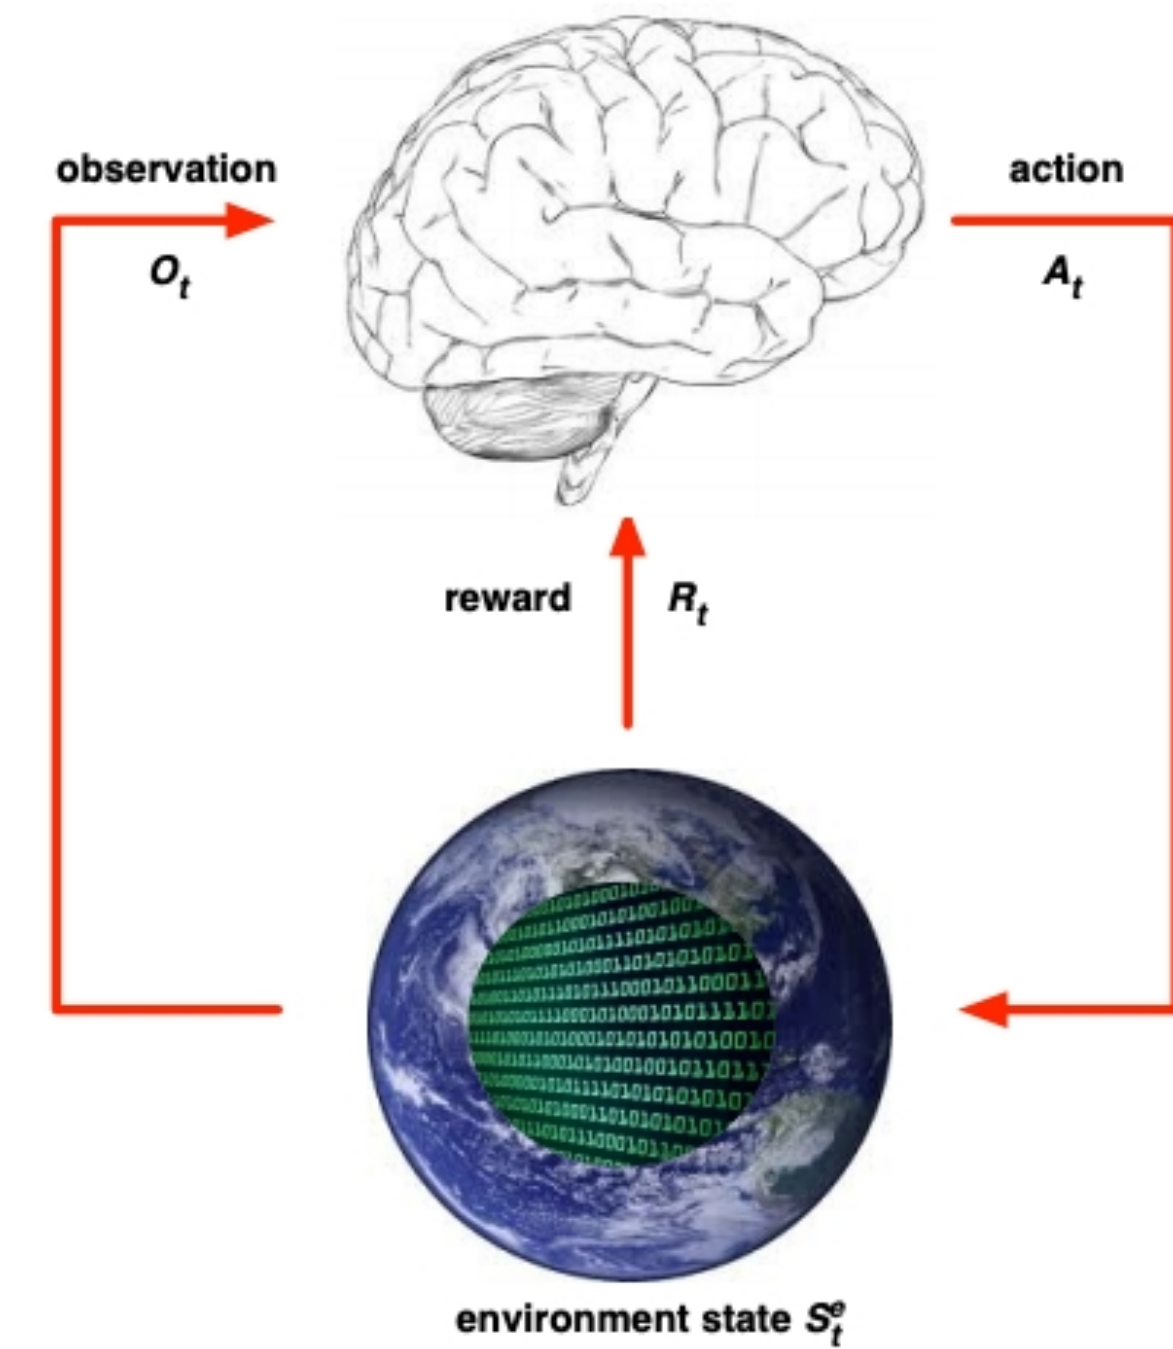


能源优化系统



通用强化学习模型：

- Agent: 主体，智能体
- 环境： 客体，交互对象（产生观测量和奖励，接收行动）
- 信号： 观测，行动，奖励



商用车运营模型：

- Agent: 商用卡车控制器
- 环境： 道路+车辆状态
- 信号： 能耗，舒适性

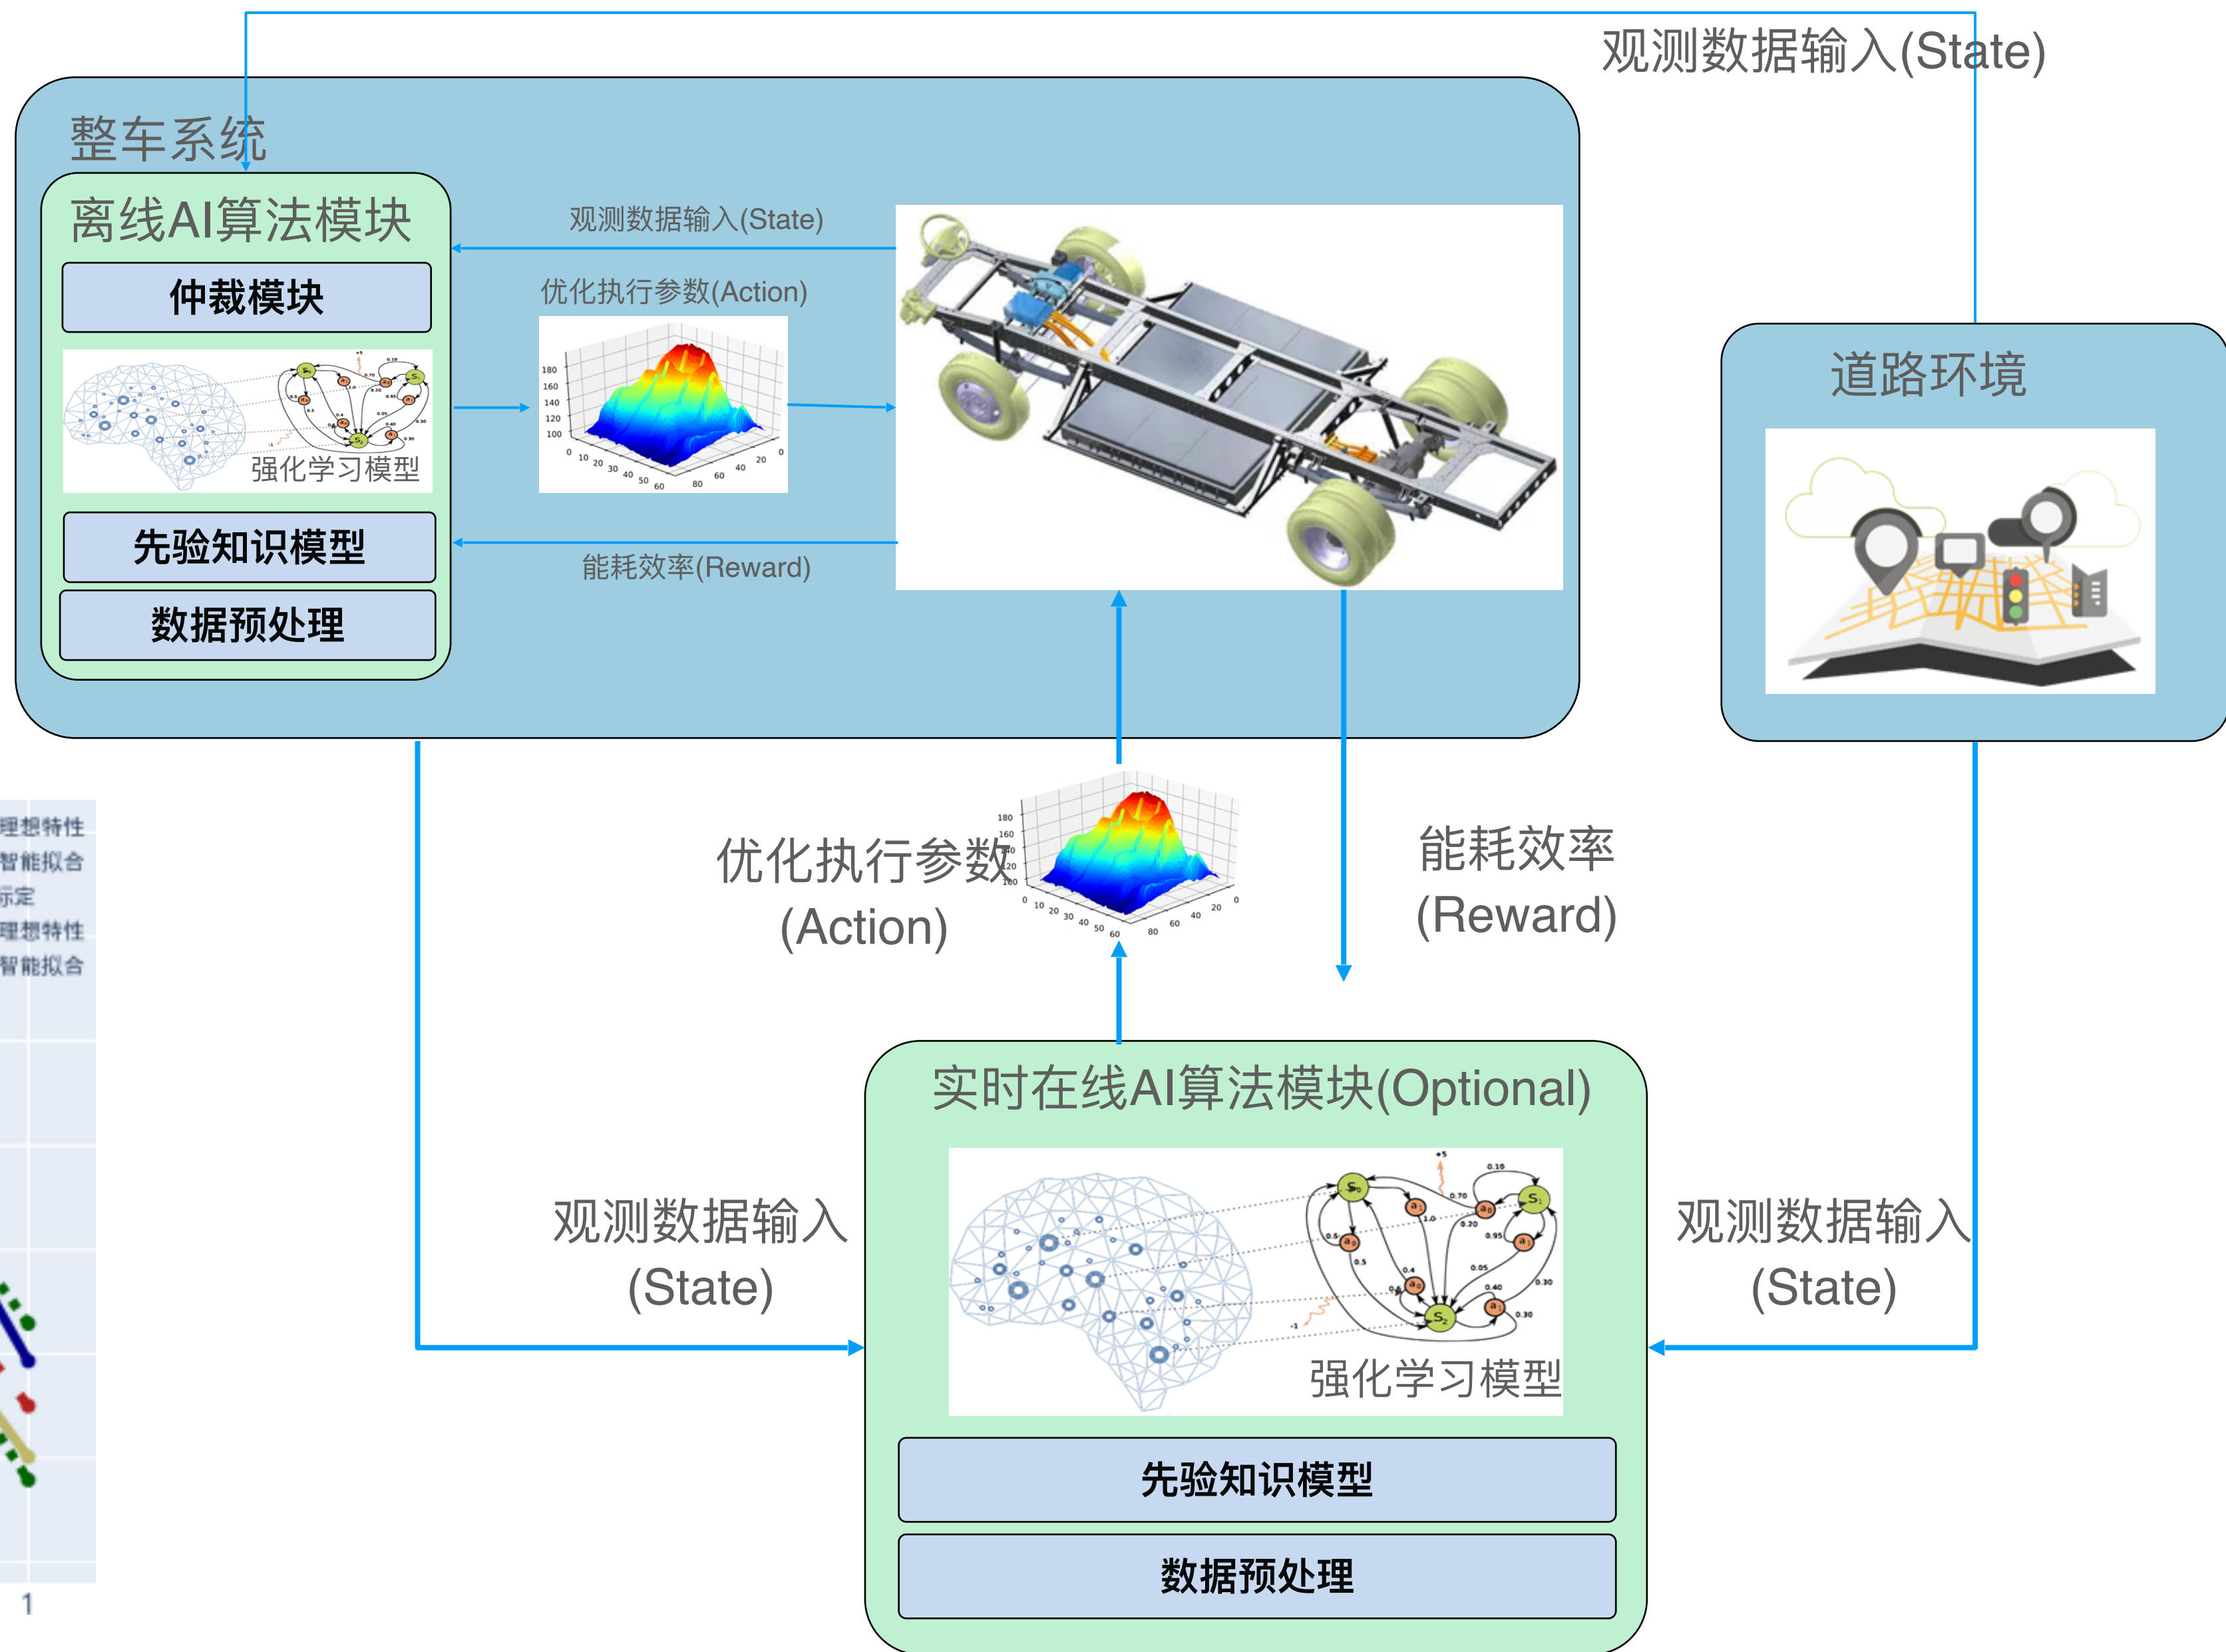




全场景AI能效优化：系统

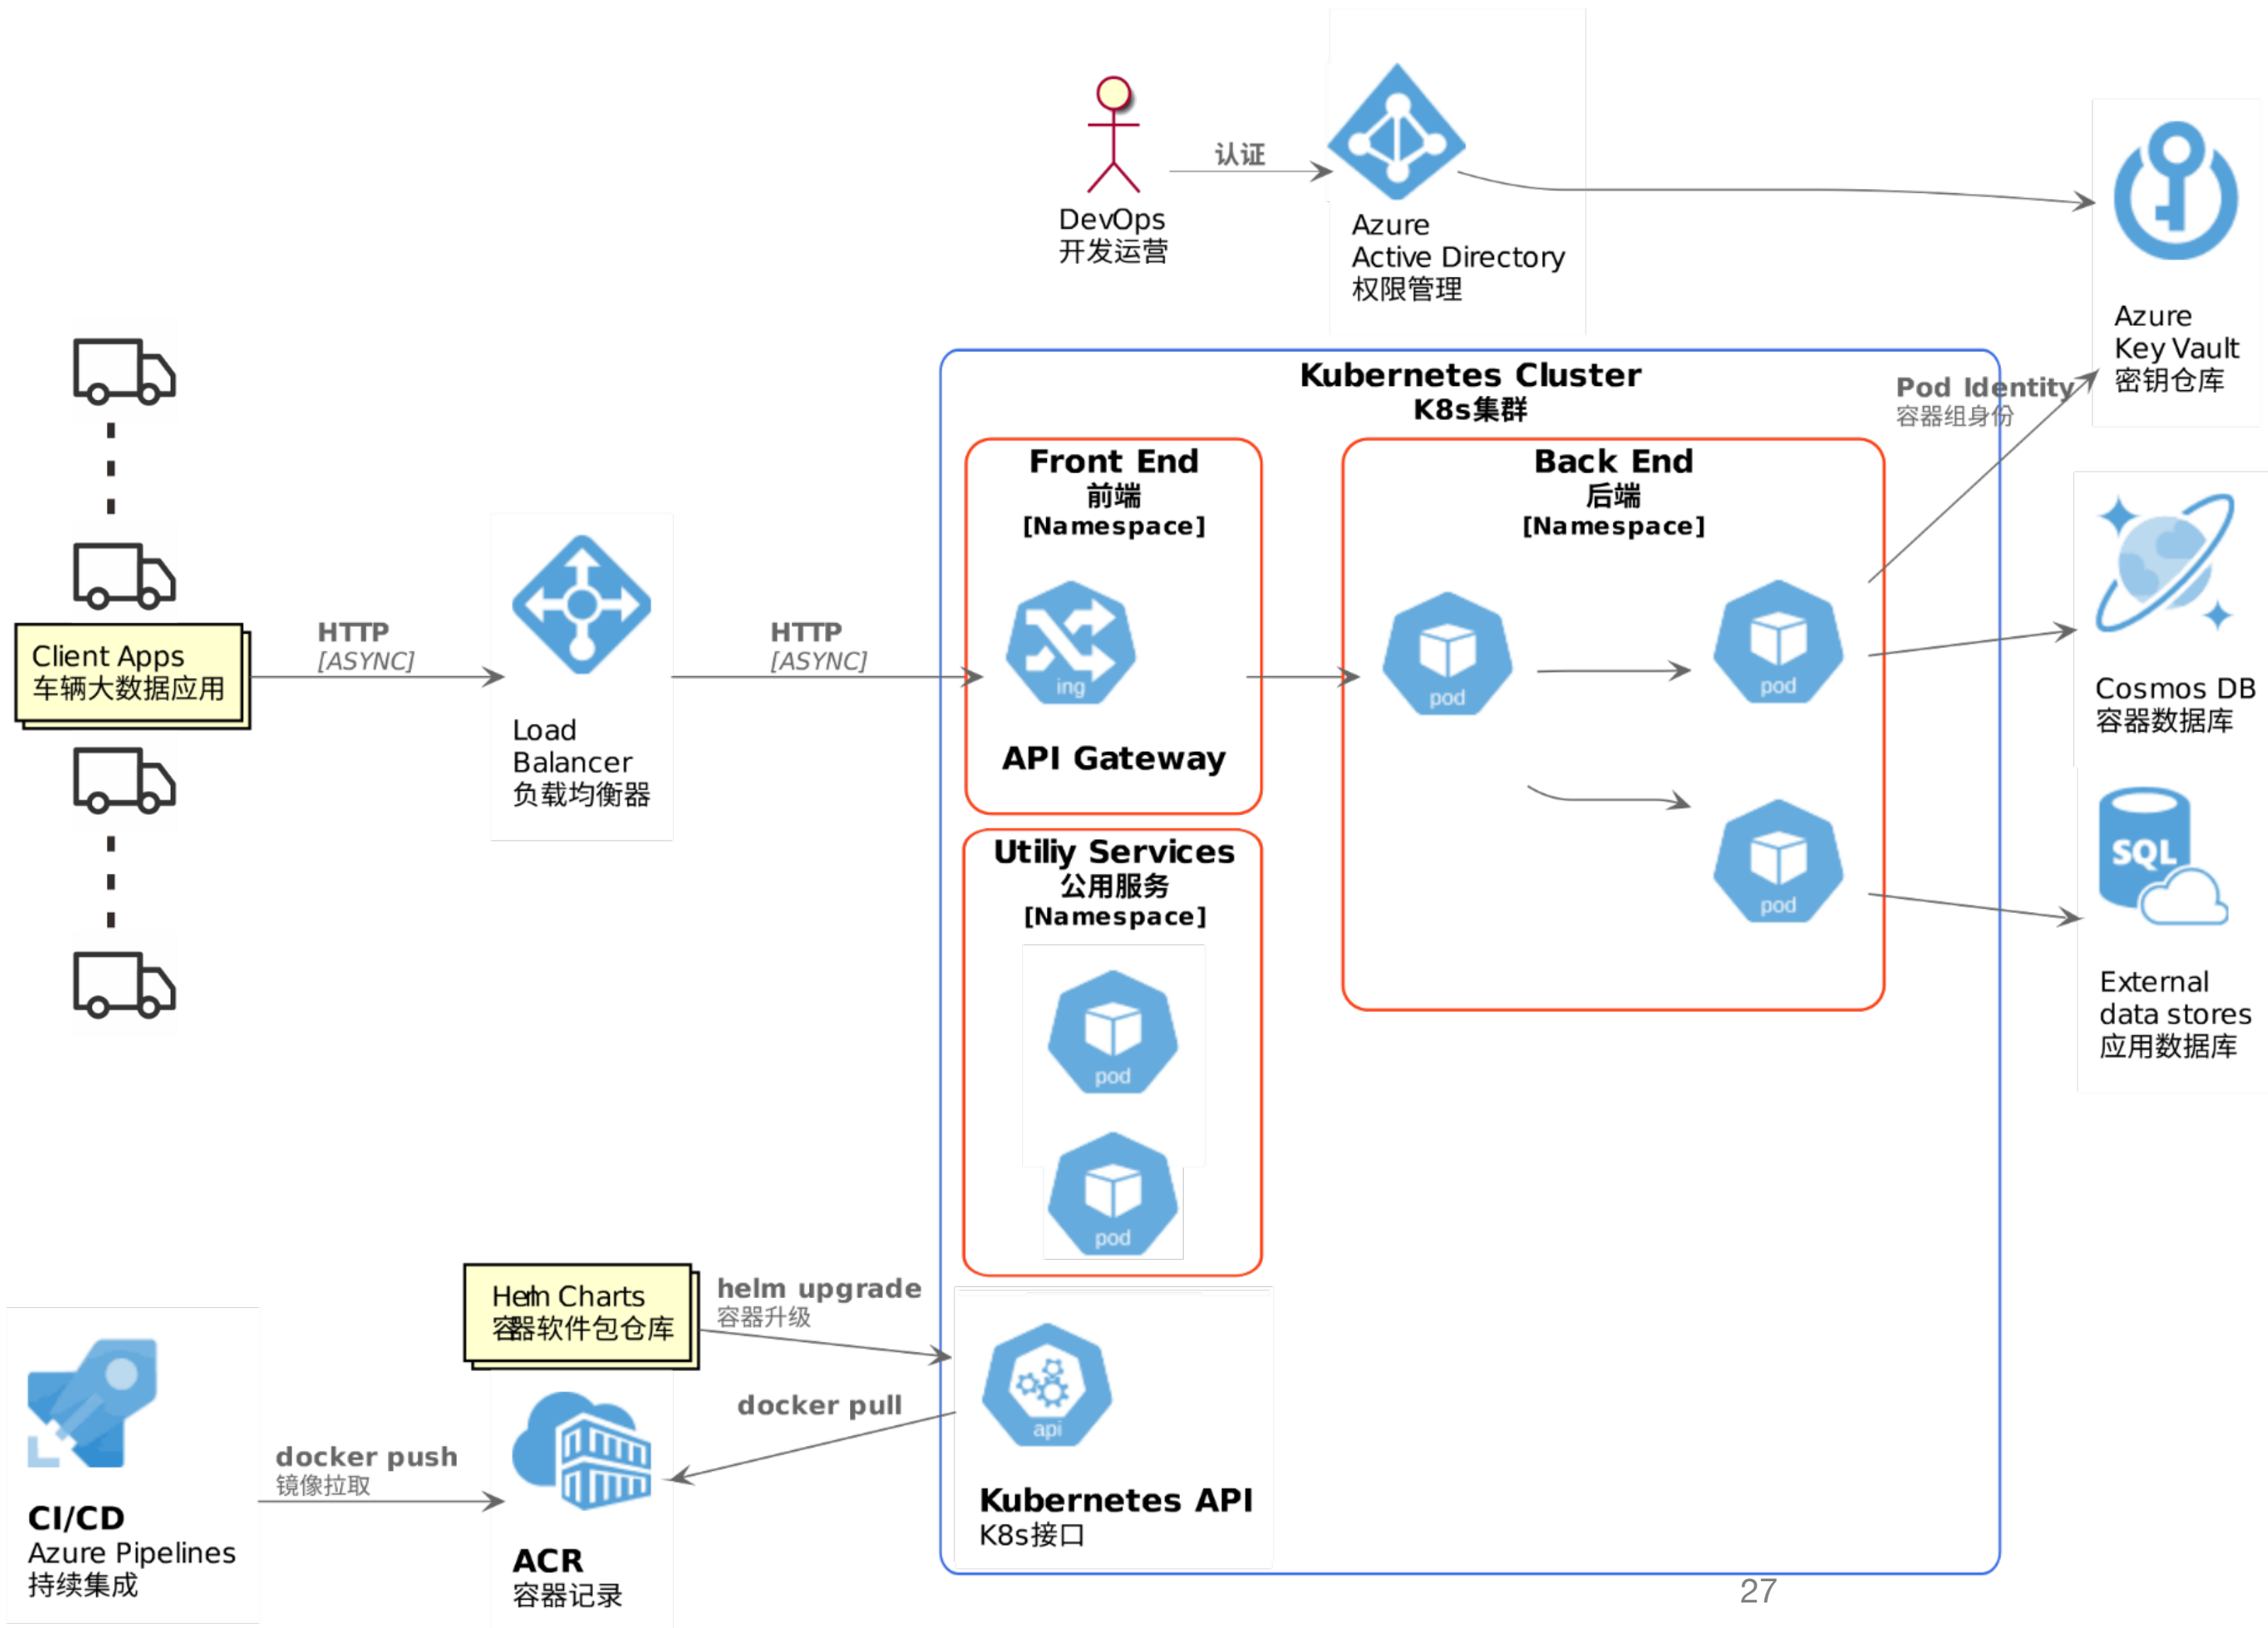
AI算法运行




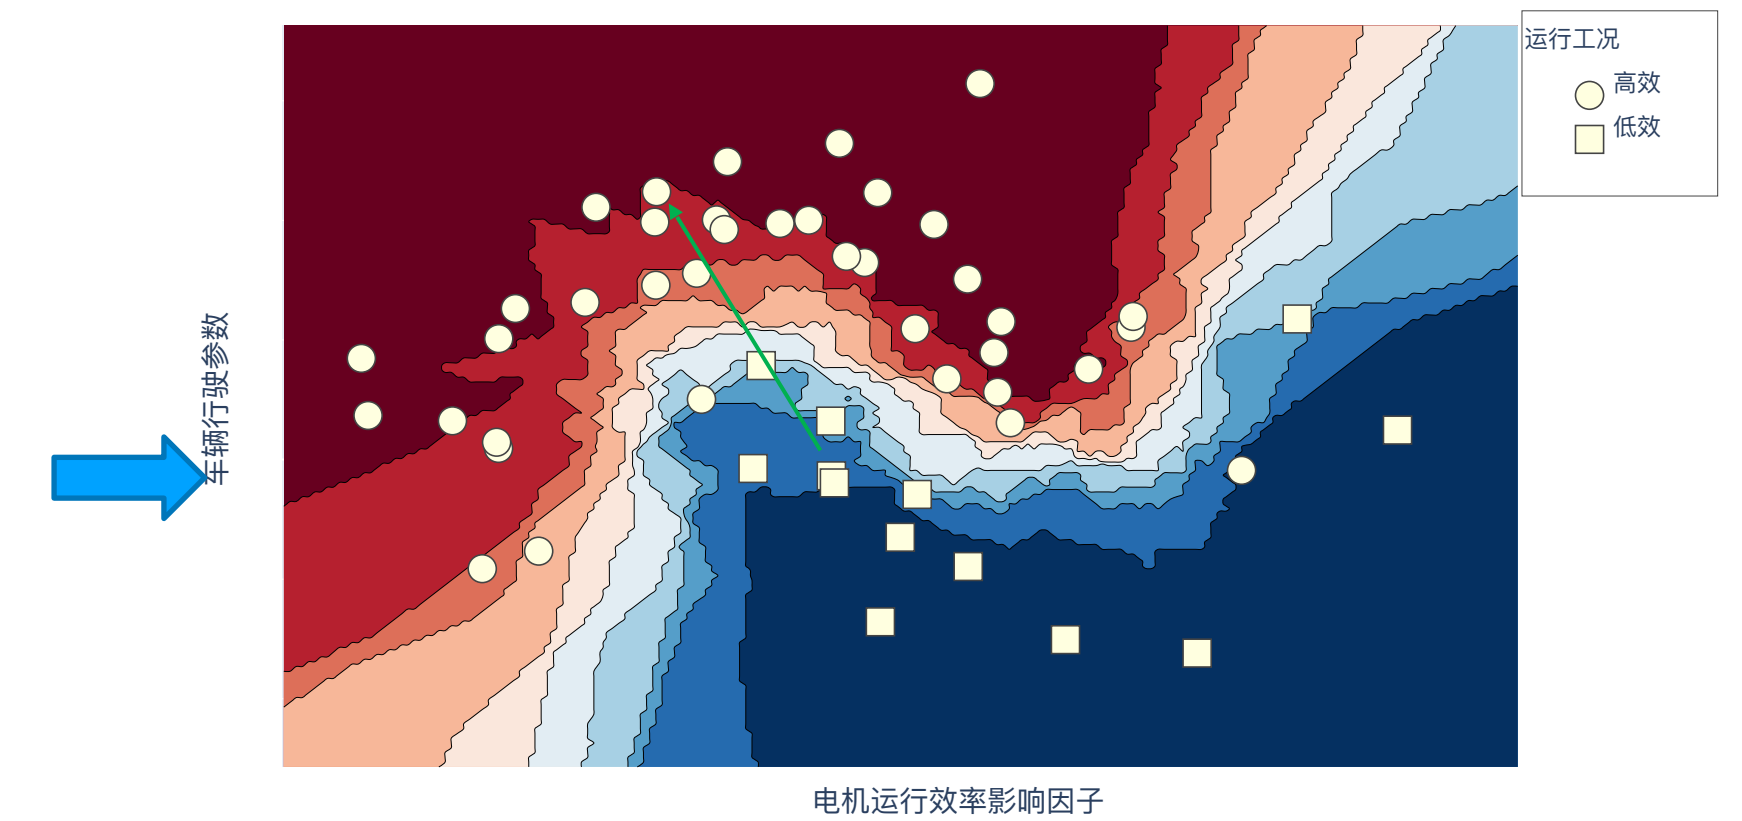
AI算法运行方式及结果



AI驱动的能效分析与优化：云架构



能耗效率特性





03



电池安全状态监控



- 单体电芯的在各使用场景中的响应
 - 场景：充电，驾驶（加速，能量回收）
 - 信号：单体电压，单体电流，静息电压
- 内在模型


$$V = f(I, T, SoC, SoS) \simeq \hat{f}(I, SoC, SoS)$$

- SoS, SoC , 温度对电压响应的影响
- 极化电阻变化
- 目标 $SoS = f^{-1}(V, I, T, SoC) \simeq \hat{f}^{-1}(V, I, SoC), SoS \in \{Good, Bad\}$

问题背景

- 优势
 - 持续收获大数据
 - 可方便通过数据引擎索引获取同工况的场景数据
 - 可追踪数据的较长趋势
- 挑战
 - 模型无法参数化，结构未知（不适用系统识别方法）
 - 测量数据非平稳过程，受使用场景，环境因素，使用行为的影响
 - 目标状态（ SoS ）本身也是非平稳过程
 - SoC使用工况无法测量
 - 温度测量不能到达电芯颗粒度
 - 极化电阻正常使用工况无法测量
 - 原始数据的噪声需要定量分类和分析
 - 不适用常规监督学习（Supervised Learning）

问题背景



How many retrieved items are relevant?

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}}$$

How many relevant items are retrieved?

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

- 对机器学习方法的挑战

- 没有监督信号

- 无法利用专家知识

- 无标注的原始数据（而且无法标注）

- 几乎没有故障电池（无负样本）

- 漏报风险非常高（漏检 FN ）

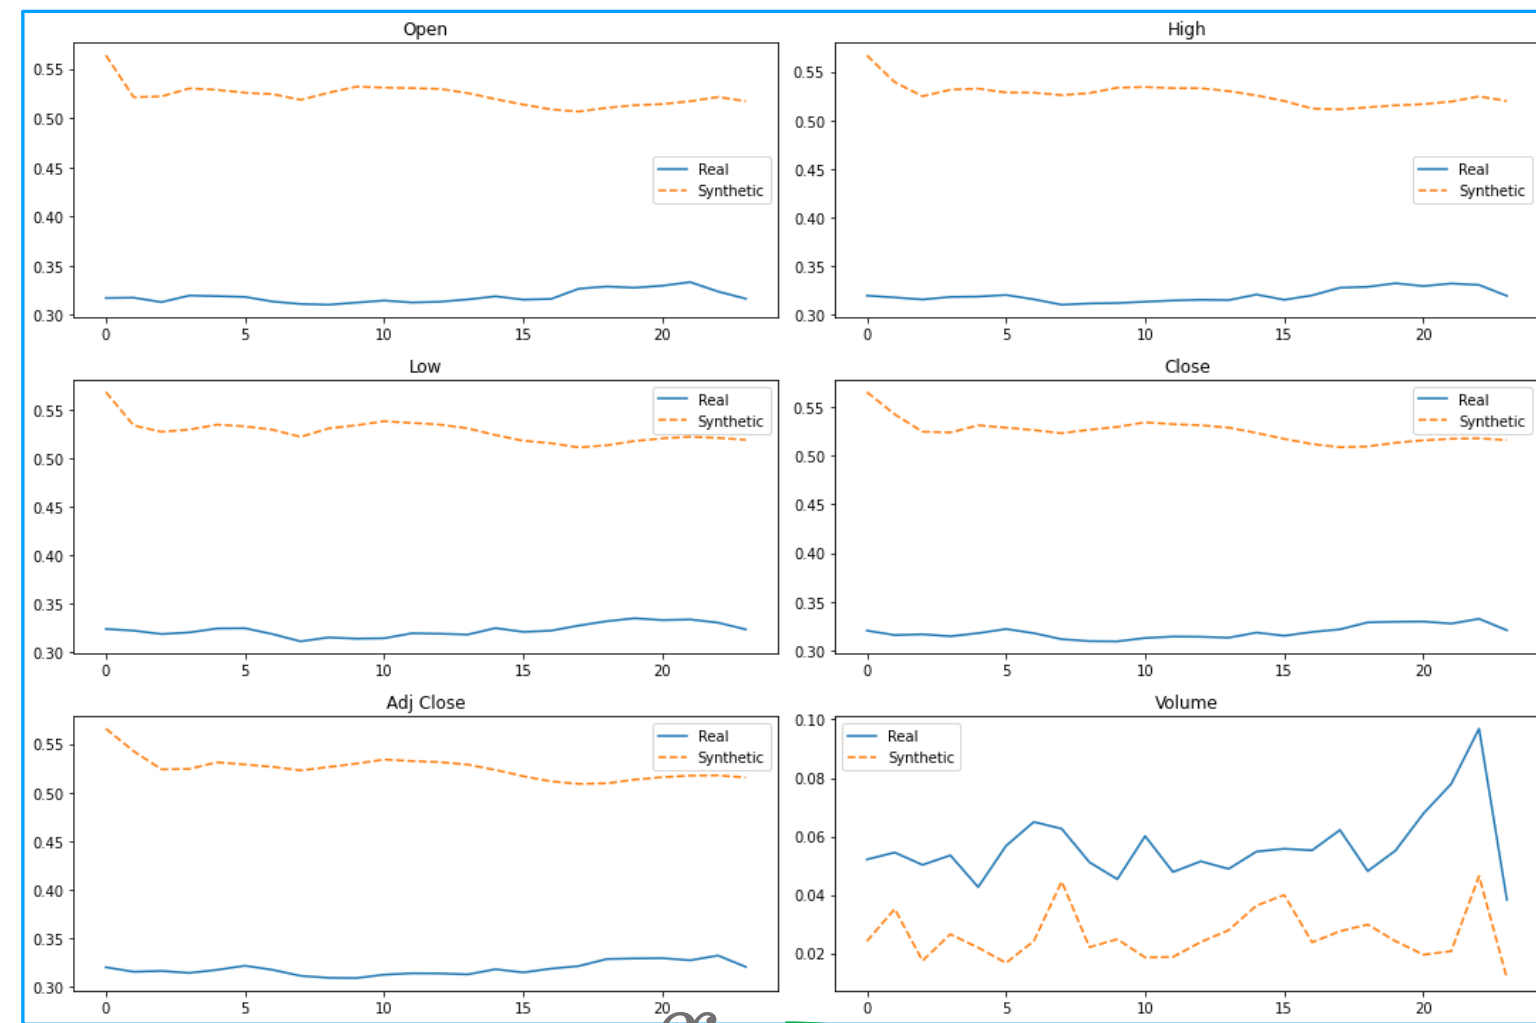
- 回调率要求非常高 $Recall = \frac{TP}{TP+FN}$

- 精度影响维护成本（误检 FP ）

- 精度要求高 $Precision = \frac{TP}{TP+FP}$

$$\alpha = \frac{\beta}{\gamma}$$

方法




• 输入信号: $\left(\mathcal{S} \times \prod_t \mathcal{X}_t \right)$

- 隐藏参数 \mathcal{S} : (SoC, SoS, T, ...)
- 时间序列观测量 \mathcal{X}_t : (I_t, U_t, \dots)

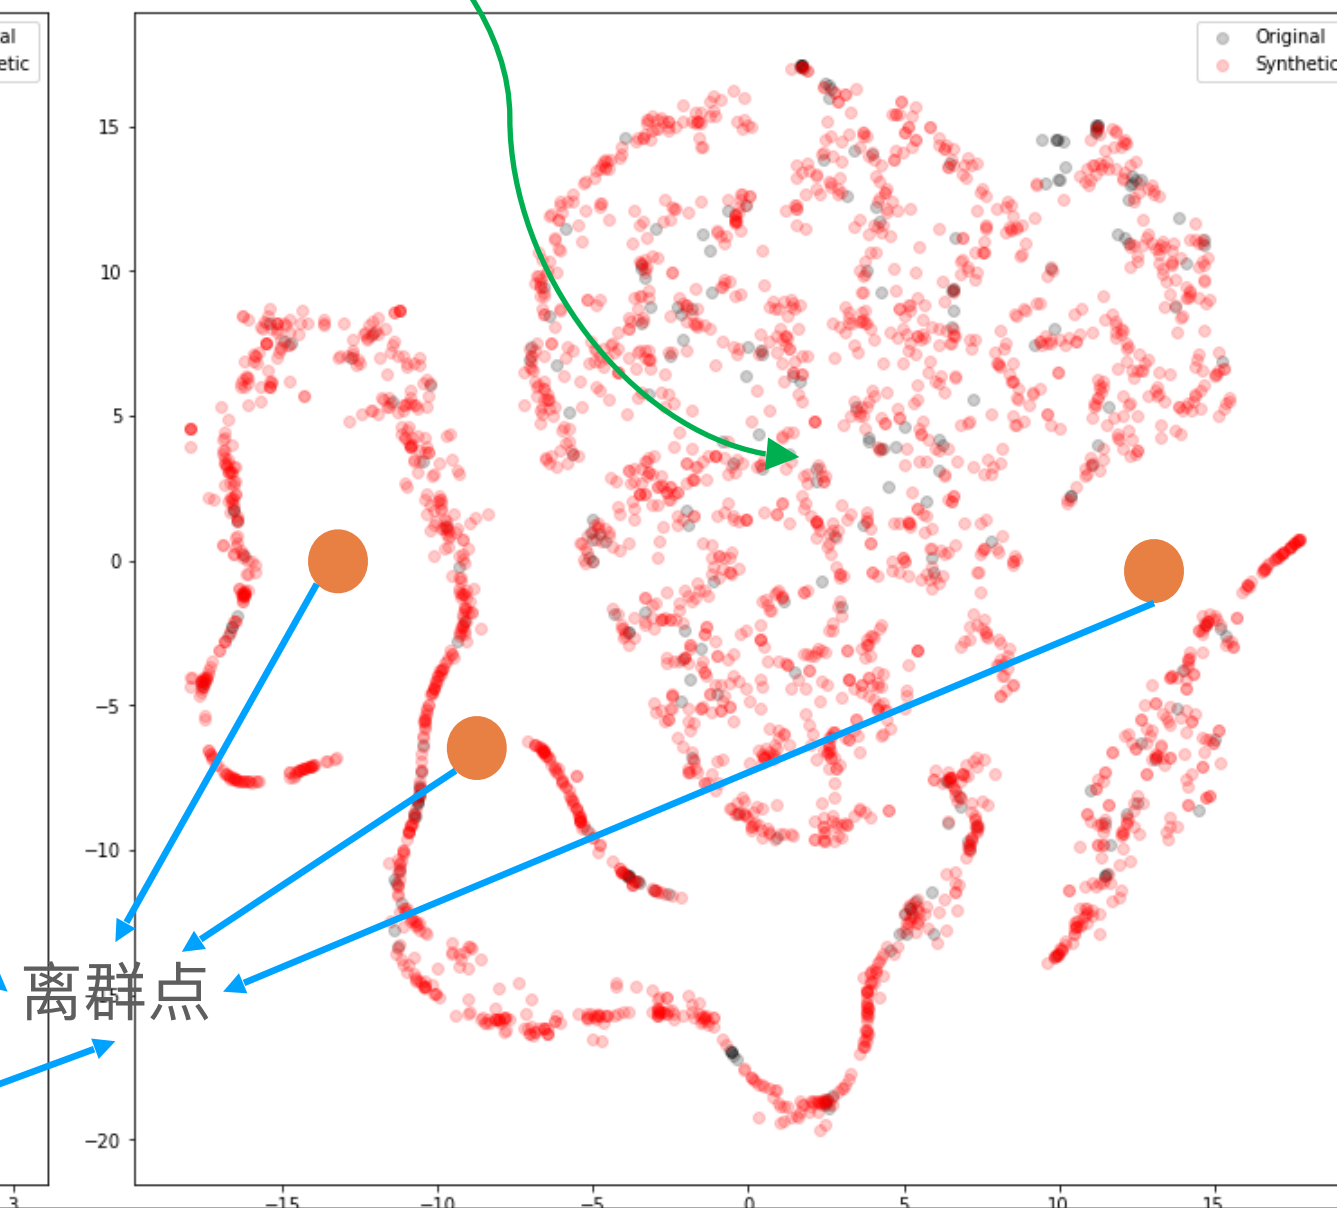
映射 / 编码

Validating synthetic vs real data diversity and distributions

PCA results



TSNE results



离群点

• 压缩的内嵌空间: $\left(\mathcal{H}_\mathcal{S} \times \prod_t \mathcal{H}_{\mathcal{X}_t} \right)$

- 压缩隐藏参数: $\mathcal{H}_\mathcal{S}$
- 压缩时间序列: $\mathcal{H}_{\mathcal{X}_t}$

• 多模态分布 (多模态场景)

• → 选择场景减少数据模态和模型容量, 加速训练

学习电池数据样本的分布，从总体上把握电池观测信号的分布，定量计算样本的离群度

- 无监督学习
- 通过自编码压缩参数空间
- 通过对抗生成网络学习观测量的分布
- 离群点识别方法：
 - 利用学习到的分布定量计算离群度
 - 直接利用鉴别器
 - 利用GAN的结果和Post Hoc分类器进行判别