

—— 第二讲

人工智能怎样进入 你的研究与实践

人工智能数学原理与算法 · 第二讲
从前沿应用理解为什么学、学什么、怎样验证。

01 量子：测量与控制

02 数学：搜索与验证

03 自然科学：实验

04 工程：设计与运行

四个方向，都有可以具体着手的任务

先关注研究中最费时的环节，再选择适合它的算法。

01

量子

从测量记录判断误差；减少校准试验。

02

数学

检索引理、寻找反例；加速数值计算。

03

自然科学

筛选材料、预测演化；安排下一次实验。

04

工程

识别故障、优化设计；辅助运行决策。

共同问题：节省了什么成本？结果凭什么可信？

前沿能力的价值，落在具体研究环节上

读案例时，分清系统已经展示的能力与我们希望它进一步做到的事。

01

预测

给定条件，估计结果。

例：材料性质、天气演化。

课程连接：回归、神经网络。

02

生成与检索

提出候选、寻找线索。

例：引理、代码、实验方案。

课程连接：自监督、注意力。

03

行动与反馈

执行一步，再根据结果调整。

例：校准、控制、程序优化。

课程连接：强化学习与评估。

本讲用代表性研究解释方法；案例年份与来源见对应页及备注。

一个可用的 AI 任务，需要五个环节

先把任务说明白，模型选择才有依据。



例：材料筛选先学会预测性质，再讨论是否值得做真实实验。

规则、学习与反馈在实际系统中协作

人工智能概述中的主要流派，为我们提供不同的解决问题思路。

01

规则与符号

明确对象、逻辑和约束。
例：形式证明检查。
要问：规则表达是否准确？

02

数据与连接

从样本中学习可用模式。
例：图像识别、性质预测。
要问：新数据是否仍适用？

03

交互与适应

让行动接受环境反馈。
例：控制、搜索与试验。
要问：短期得分代表什么？

概述课理解流派与演进；后续课程学习怎样实现其中的学习模块。

模型能学的部分，要与系统目标对应

学到某个中间指标，并不自动等于完成整个研究任务。

学习模块

输入信息，给出预测

- 误差类别或性质数值
- 下一段文本或候选代码
- 一个动作的预期收益
- 由训练目标引导参数更新

完整任务

把预测变成可验证结果

- 纠错后是否保护逻辑信息
- 证明是否有效、实验是否复现
- 设备运行是否满足约束
- 计入数据、计算与验证成本

选择损失函数之前，先说明模型输出会怎样被使用。

四个方向，分别需要怎样的新数据检验？

数据划分应模拟将来的使用场景，而不能只追求分数好看。

应用方向	模型容易记住什么	更合理的测试	真正关心的结果
量子	同一器件与噪声条件	新批次或不同噪声	逻辑误差与解码耗时
数学	近似题目与证明模板	新定理族或新题型	有效线索与验证成功
自然科学	同一骨架或实验批次	新结构或前瞻实验	预测误差与实验命中
工程	同一设备的相邻片段	新设备或未来时段	漏报、误报与延迟
共同要求	用测试结果反复调参	训练、验证、测试分工	报告基线与失败案例

泛化（对未见数据仍然有效）需要与具体使用边界一起说明。

先做一次选择：你想让 AI 帮你完成哪一步？

只选一个可以获得数据、也可以判断结果的任务。

教学情境：你只有有限的实验或计算预算，希望减少一次研究中的重复劳动。

问题

写清一个输出

一个类别、一个数值，
或下一步行动。

数据

列出输入与来源

已有测量、公开数据，
模拟结果或证明库。

证据

确定比较标准

与简单方法比较，
怎样判断有用？

先保留这张任务卡；听完四个方向与算法导读后，再回来修改。

—— 方向一 · 量子

量子方向： 让有限测量更有价值

从纠错、校准和参数估计切入，理解学习算法怎样服务量子实验。

01 测量：数据来源

02 纠错：误差判断

03 校准：试验预算

04 验证：新条件

先分清：AI 帮量子，还是量子帮 AI？

三个方向的输入、设备与证据要求不同。

01

AI 帮量子设备

校准脉冲、识别漂移、辅助纠错。
课程：分类、回归、序列学习。

02

学习量子测量数据

估计参数、识别状态、研究相变。
课程入口：统计学习与特征表示。

03

量子计算帮助学习

研究量子电路能否改进
特定学习任务。
需要另学量子算法与复杂度分析。

本课程先建立经典学习算法基础，再判断它怎样接入量子问题。

一次测量给出记录；多次测量帮助估计

先记录测量条件，再讨论模型能从中学习什么。

数据端

每条样本都要带上下文

- 准备过程与控制参数
- 测量方式与测量时刻
- 重复次数与结果计数
- 器件、批次和噪声条件

任务端

先确定要推断的对象

- 估计一个物理参数：回归
- 判断误差类型：分类
- 预测后续变化：序列学习
- 选择下一次设置：决策

同一组记录可能支持不同任务；标签必须来自可信的实验或模拟定义。

AlphaQubit：用测量历史辅助量子纠错

代表性研究：Nature，2024；核心任务是解码，而非读取完整量子态。

01

物理问题

症状随空间与时间关联。
单轮测量可能存在歧义。
目标：判断逻辑观测量的误差。

02

学习方法

循环式 Transformer 利用历史。
先用模拟样本训练，
再用实验数据微调。

03


课程连接

分类：输出误差判断。
序列模型：利用多轮历史。
注意力：联系不同测量单元。

研究成绩还要结合噪声条件、数据量与解码速度来评价。

校准问题：让每一次试验更有针对性

教学情境：设备漂移后，怎样少做一些无效的参数尝试？



回归提供预测；实验选择是额外的决策问题，不能混为一谈。

参数估计：拟合得好，还要能够区分原因

哈密顿量学习，是把量子动力学与统计推断连接起来的一类问题。

可由学习帮助的部分

从观测估计参数

- 输入不同时间的测量记录
- 输出耦合强度等未知参数
- 用损失衡量预测与观测差异
- 通过优化寻找更合适的参数

物理上必须追问的部分

这些数据能否唯一支持判断？

- 不同参数会产生相似记录吗
- 初态和测量设置是否足够丰富
- 噪声会不会放大估计偏差
- 新条件下的预测是否仍成立

学回归与优化，是为了做好估计；可识别性仍需要物理分析。

量子方向学习 AI，要抓住五个重点

专业知识决定什么能测；学习算法决定怎样更有效地使用测量。

先做一个
可解释数据来源、
可检验输出的模块。

把收益写成实验次数、逻辑误差或响应时间。

- 01 **概率与标签**
分清测量频率、真实参数和训练目标。
- 02 **分类与回归**
用明确的输入输出建立简单基线。
- 03 **时间依赖**
比较只看当前与使用历史的差别。
- 04 **迁移与漂移**
检查换器件、换批次后的表现。
- 05 **成本与约束**
同时报告测量预算、速度和物理限制。

优先补齐：概率统计、编码与测量基础，再深入复杂网络。

量子研究问题，怎样对接后续课程？

从一个能比较的基础模块开始，逐步接入真实实验。

研究问题	课程知识点	可做的小任务	必须检查
纠错解码	逻辑回归、RNN、注意力	预测简化逻辑误差	噪声变化与处理速度
器件校准	回归、梯度下降	拟合参数与性能关系	实验次数与漂移
参数估计	损失函数、神经网络	用模拟记录估计参数	可识别性与误差
相互作用结构	图表示、图卷积	学习节点与耦合信息	图结构的物理含义
连续控制	MDP、Q 学习	模拟环境中的动作选择	约束与模拟偏差

建议起步：用同一份简化纠错数据比较“当前测量”与“多轮历史”。

—— 方向二 · 数学

数学方向： 让搜索更快，让论证可靠

围绕引理检索、证明搜索、反例发现和数值计算建立应用入口。

01 检索：有用知识

02 探索：候选反例

03 验证：论证检查

04 计算：误差成本

数学前沿的两条路线，需要不同验证方式

代表性进展：2024 年形式证明系统；2026 年研究型数学智能体。

形式证明路线

AlphaProof：搜索并检查

- 用形式语言表达命题与步骤
- 语言模型提出候选证明步骤
- 强化学习利用验证反馈
- 2024 年与几何系统达银牌水平

自然语言研究路线


Aletheia：生成、审查、修订

- 2026 年公开的研究型智能体
- 结合检索与自然语言检查
- 由数学研究者共同评估结果
- 自然语言检查不等于形式证明

阅读进展时，要同时看任务范围、人工参与与正确性证据。

引理检索：先帮你缩小“找什么”的范围

教学情境：证明卡住时，从已有定理库中找到可能有用的结论。



课程连接：词向量、自监督预训练、Transformer；评价用有效候选比例。

证明搜索： 每一步都改变后续可走的路

先理解“当前目标—可选步骤—检查结果”，再理解强化学习。



状态与动作帮助描述搜索；规则决定合法性，学习帮助选择顺序。

反例发现：AI 可以找线索，证据仍要补全

数学探索需要同时保存成功例子与失败例子。

01

提出猜想

从已计算对象中观察模式。
可用回归、分类或生成方法。
要防止只挑支持自己的样本。

02

搜索反例

优先检查边界与特殊结构。
一个有效反例就能否定全称命题。
数值异常还需排除误差。

03

形成论证

大量正例不能代替一般证明。
可检验反例要满足全部条件。
新颖性还要核对已有文献。

适合数学学生的入口：让模型帮助排序待检查对象，再用精确计算验证。

数值计算：先学会控制近似误差

教学情境：一类相似方程要反复求解，能否用学习减少计算？

可以加速的环节

学习一个可重复使用的近似器

- 输入边界条件或模型参数
- 输出解的特征或近似数值
- 利用已有高精度解做训练
- 比较多次使用后的总成本

数学学生的关键判断

误差在什么范围内可接受？

- 检查边界条件与守恒关系
- 区分训练误差与新参数误差
- 考察稳定性和极端情况
- 保留高精度求解器作参照

课程连接：回归、神经网络、梯度优化；数值分析提供误差与稳定性标准。

数学方向学习 AI，要把优势用在判断上

会推导，也要会选数据、写程序和检查失败。

把逻辑、概率
与误差分析，
变成可执行的检查。

研究价值来自问题选择，也来自可重复的证据。

- 01 **线性代数**
理解向量表示、矩阵计算与图结构。
- 02 **微积分与优化**
解释梯度、链式法则及训练变化。
- 03 **概率统计**
区分训练目标、样本偏差与泛化。
- 04 **逻辑与数值分析**
检查证明前提、近似误差与稳定性。
- 05 **编程与实验**
实现基线，保存结果，诊断失败。

优先关注：反向传播、优化方法、表示能力的条件与泛化证据。

数学研究兴趣，可以落到这些算法接口

选择一个范围有限、评价清楚的任务作为起点。

研究兴趣	课程知识点	可做的小任务	判断标准
证明与形式化	词向量、Transformer	目标到引理的检索	前几项候选是否可用
离散与组合	分类、图神经网络	给待搜索结构排序	验证后节省多少搜索
数值与方程	回归、神经网络	拟合一族简单方程的解	误差、稳定性与总成本
优化理论	梯度下降、SGD、Adam	比较同一模型的训练	收敛过程与新数据表现
决策与搜索	MDP、贝尔曼方程	小型可验证搜索环境	成功率与搜索预算

建议起步：做一个小型引理检索器，并人工核对返回候选的适用条件。

—— 方向三 · 自然科学

自然科学方向： 让预测进入实验检验

围绕材料、分子、天气与实验选择，理解 AI 怎样提高研究效率。

01 预测：计算加速

02 表示：结构关系

03 实验：有效信息

04 机制：独立检验

材料筛选：先减少需要认真验证的候选数

教学情境：面对很多配方，实验预算只允许测试少量候选。



模型的价值，要看真实实验命中率与节省的预算。

GraphCast：把空间关系用于天气预测

代表性研究：2023；图神经网络学习天气状态的演化。

—— 01

输入与目标

利用历史天气状态，
预测后续天气变量。
任务包含空间与时间关系。

—— 02

为什么使用图

把空间位置组织成连接结构。
邻域信息逐层传递，
支持不同区域之间的信息交换。

—— 03

课程连接

节点、边与图表示。
邻居信息聚合。
连续预测中的误差累积。

预测模型依赖高质量历史资料；具体效果要按地区、变量与时段评价。

分子性质：相同元素数量也可能有不同结果

结构决定哪些原子相互关联，图表示让这些关系进入模型。

—— 01

怎样表示

节点：原子及其特征。
边：化学键或指定相互作用。
几何任务还需要空间信息。

—— 02

怎样学习

聚合邻居的特征。
更新每个原子的表示。
汇总得到分子级预测。

—— 03

怎样检验

区分图分类与图回归。
留出新的分子骨架。
检查物理约束与适用范围。

课程连接：邻接矩阵、图卷积与图级任务；化学知识决定输入是否充分。

机器化学家：把预测接回真实实验

中国科大代表性研究：2023 年，利用火星陨石原料研究析氧催化剂。



这是地面实验研究；预测器、实验选择与仪器执行承担不同职责。

预测准确与机制解释，需要不同证据

一个相关性模式，可以成为实验线索；它还需要接受进一步检验。

预测问题

在给定条件下，结果是什么？

- 比较未见样本上的误差
- 检查分布变化是否影响性能
- 报告不确定性与失败范围
- 用于排序候选和分配预算

机制问题

为什么发生，改变条件会怎样？

- 提出可以区分解释的实验
- 检查变量关系与物理约束
- 排除其他合理的解释
- 由独立实验或推导复核

课程帮助建立预测器；科学解释还依赖干预、理论与实验。

自然科学方向，重点是数据与物理含义

让领域知识参与输入设计、评价方式和失败分析。

**让模型帮助
提出更好的候选，
让实验判断结果。**

记住：模型置信度不等于科学结论的可信度。

01 单位与条件

保留量纲、实验协议与采样来源。

02 结构与表示

分子、晶体、空间场各有适合的表示。

03 训练与外推

换结构、换条件后单独验证。

04 不确定性

用可检验的方法判断预测何时不可靠。

05 实验反馈

新实验用于修正模型，也用于排除解释。

优先关注：数据与特征、回归、图网络、自监督目标与泛化。

自然科学的研究对象，决定算法怎样接入

把 “AI 加速科学” 落实到一个可以测量收益的环节。

研究对象	课程知识点	学习任务	验证重点
材料与配方	回归、特征工程	预测性质、排序候选	新批次与实验命中率
分子与相互作用	图卷积、图级任务	结构到性质的预测	骨架划分与几何信息
天气与时空场	GNN、序列学习	预测后续状态	区域差异与长程误差
谱图与图像	卷积、自监督学习	提取特征、识别异常	测量条件与伪相关
实验参数选择	预测、优化、决策基础	在预算内选择下一实验	约束、复现与信息收益

建议起步：在一个公开性质数据集上，比较平均值、线性回归与小型网络。

—— 方向四 · 工程

工程方向： 把模型放进可运行的流程

围绕设备诊断、设计优化、感知与控制，理解算法怎样产生实际收益。

01 诊断：发现问题

02 设计：减少试算

03 控制：长期收益

04 运行：响应速度

设备诊断：让告警更早，也更有用

教学情境：由振动、温度等运行记录判断设备是否异常。



分类准确率之外，还要看漏报率、误报率、提前量与推理耗时。

设计优化：用近似模型减少昂贵试算

教学情境：改变结构或参数，需要反复进行仿真与试制。

学习模型负责

快速估计候选设计的表现

- 输入几何参数、材料与工况
- 输出性能、成本或约束指标
- 回归或网络近似仿真结果
- 用预测筛选有希望的候选

工程验证负责

确认设计能够满足要求

- 高精度仿真复核关键候选
- 检查极端工况与约束边界
- 必要时进行试制与测量
- 比较训练、搜索及验证总成本

课程连接：回归、神经网络、梯度优化；优化变量与网络参数要分清。

感知与指令融合，让模型理解任务上下文

机器人和多传感器系统需要知道看见了什么，也需要知道要做什么。

01

局部感知

图像与信号中识别模式。
课程入口：卷积、池化。
关注：遮挡、噪声、采样差异。

02

历史信息

由多帧或多时刻判断变化。
课程入口：RNN、LSTM、GRU。
关注：记忆长度与时间对齐。

03

跨输入关联

把指令与相关观测联系起来。
课程入口：token、注意力。
关注：对齐与任务训练目标。

把多种输入放在一起，还需要训练目标与反馈才能学到有用联系。

连续控制：一次动作会影响下一次处境

教学情境：在模拟环境中选择动作，使系统长期表现更好。



课程连接：MDP、蒙特卡洛、Q 学习与 DQN；真实应用还要满足控制约束。

AlphaEvolve：用执行结果推动代码与算法改进

代表性研究：2025；生成候选、自动评估与进化搜索相结合。

01

模型能帮助什么

提出程序或算法候选。
基于已有结果修改方案。
减少人工枚举的负担。

02

评估器决定什么

测试正确性与运行表现。
拒绝不满足要求的候选。
定义什么算一次改进。

03

课程提供什么

自监督与 Transformer 理解生成。
训练目标理解学习导向。
基线与测试理解评估。

进化搜索与梯度下降是不同方法；通过有限测试也不等于一般性正确证明。

工程方向，重点是把性能放进使用条件

同一个模型，在不同设备、预算和失败代价下，可能有不同价值。

**把模型准确性
转成可运行、
可维护的结果。**

评估单位应与业务或设备目标一致。

01 数据工程

区分设备、时间、工况，保留采集信息。

02 误差代价

分别衡量漏报、误报与延迟。

03 计算预算

检查推理耗时、内存与更新成本。

04 分布变化

新工况需要监测、验证与适应。

05 系统反馈

记录失败，明确复核与恢复方式。

优先关注：分类与特征、卷积与序列、稳定训练、决策与评估。

工程任务与算法，需要逐项对应

先做离线比较，再把模型接到真实工作流程。

工程任务	课程知识点	直接作用	重点检查
设备诊断	逻辑回归、卷积、RNN	识别异常与变化趋势	漏报、误报与提前量
设计筛选	回归、神经网络	近似昂贵仿真	边界误差与总成本
多源感知	卷积、注意力、token	融合相关输入信息	对齐、遮挡与噪声
控制与调度	MDP、Q 学习、DQN	比较动作的长期收益	约束、延迟与迁移
代码与流程助手	自监督、Transformer	生成并修改候选方案	独立测试与任务成功率

建议起步：用同一套设备数据，比较逻辑回归与一个小型序列模型。

40 学时，怎样连接四个方向的应用？

概述 4 学时建立问题意识；后续 36 学时逐步学习算法。

01

先学预测与训练

机器学习基础 | 8 学时
数据、分类与回归、梯度下降

神经网络基础 | 8 学时
前馈与卷积、反向传播
稳定训练、RNN 与门控网络

02

再学结构与关联

图神经网络 | 4 学时
图表示、图卷积、图任务

Transformer | 6 学时
注意力、位置与多头
编码器、解码器、跨模态

03

再学信号与决策

自监督学习 | 6 学时
n-gram、词向量、BERT、GPT
预训练、微调与生成

强化学习 | 4 学时
蒙特卡洛、MDP、Q 学习、DQN

每学一个算法，都回到自己的任务卡：它解决了其中哪一步？

先问学习信号从哪里来，再给方法分类

学习方式、任务类型和数据到达方式，是不同的划分角度。

监督信号

数据提供了什么目标？

- 有监督：给定输入及目标结果
- 无监督：寻找无外部标签的结构
- 半监督：少量标签加无标签数据
- 自监督：由数据自身构造目标

交互与时间

数据怎样产生，模型怎样更新？

- 强化学习：行动得到环境奖励
- 增量学习：新数据到达后更新
- 分类预测类别；回归预测数值
- 同一模型可先预训练再监督微调

例：设备信号可以先自监督学习，再用少量故障标签训练分类器。

数据与特征决定模型实际看见什么

先确定一条样本、一个输出和一种合理的数据划分。

01

表格与类别

温度、配比、设备型号；统一单位与编码。

03

图与文本

分子连接、证明语句；保留结构与上下文。

02

信号与图像

测量序列、谱图、照片；保留时间与采样条件。

04

特征与任务

分类或回归先说清；线性或非线性再比较。

标准化参数只在训练集上估计，再应用于验证集与测试集。

线性回归：先把一个预测器讲清楚

教学示例：所有数值均为无量纲，用来理解计算过程。

预测

$$\text{预测值} = w \times x + b$$

- x 是输入特征； w 是权重
- b 是偏置； y 是目标值
- 取 $x = 2$, $w = 1$, $b = 0$
- 预测值为 2，目标 $y = 4$

误差

$$\text{损失} = (\text{预测值} - y)^2 / 2$$

- 本例误差为 $2 - 4 = -2$
- 损失为 $(-2)^2 / 2 = 2$
- 多个样本通常取平均损失
- 拟合参数后还要测试新数据

应用入口：性质预测、设备趋势、校准性能与数值近似。

逻辑回归：把打分变成类别概率

适用于正常与异常、是否合格等二分类任务。

概率输出

$$p = 1 / (1 + \exp(-z))$$

- z 是特征的线性打分
- $\exp$ 表示以 e 为底的指数函数
- $z = 0$ 时, $p = 0.5$
- $z = \ln(3)$ 时, $p = 0.75$

训练与使用

高概率还要接受独立检验

- p 表示正类的预测概率
- 交叉熵惩罚不相信真实类别
- 真实类别为 1: 损失 = $-\ln(p)$
- 阈值按漏报与误报代价选择

应用入口：简化纠错分类、设备异常判断、候选是否合格。

梯度下降：沿能减小误差的方向改参数

继续使用 $x = 2$ 、 $y = 4$ 、 $w = 1$ 、 $b = 0$ 的教学例子。

更新规则

新参数 = 旧参数 - 学习率 $\times$ 梯度

- 对 w 的梯度 = 误差 $\times x = -4$
- 对 b 的梯度 = 误差 = -2
- 学习率取 0.1，同时更新参数
- w 变为 1.4， b 变为 0.2

更新之后

重新预测，并检查损失变化

- 预测值 = $1.4 \times 2 + 0.2 = 3$
- 新损失 = $(3 - 4)^2 / 2 = 0.5$
- 全量梯度下降使用全部训练样本
- SGD 用样本或小批量估计梯度

学习率过大可能使损失上升；训练误差下降也不等于泛化变好。

神经网络：让中间特征也能从数据中学习

先理解计算层的作用，再讨论网络能够表达什么。

01

前馈与神经元

输入加权，再经过非线性激活。
多层逐步形成中间特征。
例：由配方预测复杂性质。

02

卷积与池化

卷积在不同位置共享局部计算。
池化压缩邻域信息。
例：图像、谱图与信号识别。

03

万能近似定理

在适当条件下能够逼近函数。
这是表达能力的存在性结论。
训练成功与泛化仍需检验。

去掉所有非线性激活，多层线性变换仍可合并为一层。

反向传播与稳定训练，让网络真正学得动

先学会计算梯度，再理解为什么深层网络需要额外设计。

**反向传播算梯度；
优化器用梯度
更新参数。**

表达能力、可训练性与泛化，需要分别评价。

- 01 链式法则与反向传播**
复用局部导数，逐层计算参数影响。
- 02 梯度消失与初始化**
连乘可能衰减；初值要控制数值尺度。
- 03 残差与归一化**
保留信息通路，并调整中间数值尺度。
- 04 SGD 与 Adam**
比较随机更新与按历史梯度调整步长。
- 05 Dropout 与泛化**
训练时随机屏蔽部分单元，再检验新数据。

课程重点：反向传播、梯度消失、残差、归一化与参数初始化。

序列网络：让模型利用“发生过什么”

同一个当前观测，可能对应不同的变化趋势。

01

RNN：保存状态

循环神经网络按时间更新记忆。
同一套参数在各时刻复用。
适合建立序列计算的直觉。

02

LSTM：控制记忆

长短期记忆网络使用门控。
管理保留、写入与输出。
缓解长程依赖的学习困难。

03

GRU：简化门控

门控循环单元管理状态更新。
结构相对简洁。
与 LSTM 的优劣需要实测。

应用连接：量子测量历史、设备变化趋势、实验过程与控制状态。

图神经网络：让连接关系进入计算

不只看每个对象有什么特征，还看它与谁相连。

01

图的数学表示

节点表示对象，边表示关系。
A：邻接矩阵；D：度矩阵。
 $L = D - A$ ：图拉普拉斯矩阵。

02

图卷积的直觉

空域：收集并聚合邻居信息。
频域：在图信号模式上滤波。
节点重新编号不应改变任务含义。

03

输出什么任务

节点分类：判断单个对象。
链接预测：判断关系是否存在。
图分类或回归：预测整体属性。

应用连接：分子性质、相互作用网络、空间场与组合结构。

注意力：按当前输入决定应该参考谁

核心是计算相关程度，再做加权汇总。

01

计算关联

Q：当前查询；K：可匹配特征。
比较 Q 与 K，得到相关打分。
softmax 把打分转为权重。

02

汇总信息

V：各输入提供的内容。
教学权重：0.75 与 0.25。
 $0.75 \times 2 + 0.25 \times 6 = 3$ 。

03

组成 Transformer

位置编码补充顺序信息。
多头学习不同的关联方式。
编码器理解输入，解码器生成。

应用连接：引理检索、测量关联、指令与图像融合；权重不是环境奖励。

自监督学习：数据自身可以提供训练目标

先学习可迁移的表示，再用任务数据适应具体用途。

01

统计与词向量

n-gram：利用有限长度上下文。
word2vec：学习词的向量表示。
语言中的上下文提供学习信号。

02

BERT 与 GPT

BERT：根据两侧上下文填空。
GPT：根据前文预测后续 token。
生成时逐个续写，再加入上下文。

03

预训练与微调

预训练先学习一般表示。
微调适应领域与目标任务。
预训练不一定都属于自监督。

应用连接：引理与代码、科学文献、无标签信号；生成流畅仍要验证事实。

强化学习：用行动经验估计长期收益

先建立 MDP，再理解蒙特卡洛、贝尔曼关系与 Q 学习。

问题描述

状态、动作、奖励与转移

- 状态概括当前决策所需信息
- 动作改变后续状态和收益
- 蒙特卡洛用采样回报估计平均值
- Q 表示状态下某动作的价值

一次 Q 更新

目标 = 奖励 + 折扣 × 后续最好价值

- 教学值：旧 $Q = 2$ ，奖励 = 1
- 折扣 0.9，后续最好价值为 4
- 目标 = $1 + 0.9 \times 4 = 4.6$
- 新 $Q = 2 + 0.1 \times (4.6 - 2) = 2.26$

DQN 用神经网络近似 Q；课程将进一步讲经验回放与目标网络。

带着自己的问题，进入下一次算法课

先完成一个小闭环：数据、基线、训练、测试与失败分析。

01

量子：简化解码

比较当前记录与测量历史；检查噪声变化。

02

数学：引理检索

比较关键词与向量检索；核对引理前提。

03

自然科学：性质预测

比较平均值、线性回归与网络；留出新结构。

04

工程：设备诊断

比较统计特征与序列模型；留出新设备。

下一课起点：线性回归。先写清输入与目标，再算预测、损失和一次更新。