



《人工智能导论》课程报告

题目： 《人工智能导论》
课程报告

姓 名 余俊杰
学 号 24363120
院 系 智能工程学院
专 业 智能科学与技术

2025年05月16日

目录

1	课程内容总结	1
1.1	人工智能概述	1
1.1.1	概念解析	1
1.1.2	发展简史	1
1.1.3	决定因素	1
1.1.4	人工智能三大学派	2
1.1.4.1	符号主义	2
1.1.4.2	连接主义	2
1.1.4.3	行为主义	2
1.2	生成式人工智能	2
1.2.1	概述	2
1.2.2	发展历史	2
1.2.2.1	早期生成模型理论	2
1.2.2.2	生成神经网络的发展	2
1.2.2.3	生成式人工智能热潮	2
1.2.3	生成式人工智能产业	3
1.2.4	主要应用	3
1.2.4.1	文生图	3
1.2.4.2	文生视频	3
1.3	计算机视觉	4
1.3.1	概述	4
1.3.2	应用实例	4
1.3.2.1	图像分类	4
1.3.2.2	目标检测	4
1.4	自动驾驶与智能网联汽车	4
1.4.1	概述	4
1.4.2	自动驾驶汽车分类	5
1.4.3	典型应用场景	5
1.4.4	存在问题	5
1.5	机器人	5
1.5.1	工业机器人	5
1.5.1.1	概述	5
1.5.1.2	关键技术	6
1.5.2	特种机器人	6
1.5.2.1	概述	6
1.5.2.2	水下特种机器人	6
1.6	智慧医疗	6
2	扩散模型	7

2.1 概述	7
2.2 原理介绍	7
2.2.1 前向过程	7
2.2.2 逆向过程	8
2.3 优势	8
2.4 应用	9
2.4.1 图像生成	9
2.4.2 自然语言处理	9
2.4.3 多模态	9
2.5 扩散模型的加速采样器	10
2.6 未来展望	10
2.6.1 重新审视实际情况	10
2.6.2 从离散时间到连续时间	10
2.6.3 推广到复杂场景和更多研究领域	10
3 课程感想	11
参考文献	12

1 课程内容总结

1.1 人工智能概述

1.1.1 概念解析

人工智能(Artificial Intelligence)是由机器或者软件表现出来的, 开发用于模拟延伸和拓展人的智能的理论、方法、技术以及应用系统的一门新的技术科学。对人工智能的研究具有极高的技术性和专业性, 并且有许多相互之间具有较高专业壁垒的细分领域。中心问题主要包括演绎推理和解决问题、知识表示、目标规划、机器学习、自然语言处理等。核心目标是让机器完成只有人才能完成的智能工作。

1.1.2 发展简史

表 1.1 人工智能发展简史

时间	特点
1950 年	图灵测试被提出
1956 年	达特茅斯会议召开, AI 诞生
1956-1974 年	人工智能黄金时期, 高速发展
1974-1980 年	莱特希尔报告提出后, 人工智能进入寒冬
1980-1987 年	人工智能再次进入繁荣期
1987-1993 年	人工智能第二次寒冬
1993-2011 年	人工智能稳健发展的时代
2012 年至今	大数据驱动人工智能发展

1.1.3 决定因素

人工智能性能决定三要素包括数据、算力与算法。其中, 由于人工智能训练模型所需参数量大, 计算能力需求高, 计算成本也较高。与此同时, 算力与经济增长密切相关。《2022-2023 全球算力指数评估报告》指出, 每提高 1 个算力指数点, 数字经济和 GDP 将分别增长 3.3% 和 1.8%。目前中国算力集中在东部沿海发达城市, 逐渐向内地扩展。同时人工智能行业渗透度逐渐提高, 涉及互联网、金融、政府等多个行业和领域。

而算法解决的是计算机怎么学习的问题。常见的感知算法涉及视觉点云匹配、SLAM 等问题; 常见规划算法基于搜索、采样等, 涉及贝塞尔曲线、样条曲线等; 常见的控制算法包括经典控制理论、现代控制理论和非线性控制理论等。算法的突破对提高人工智能性能至关重要。

人工智能对数据的要求多种多样，视应用场景的不同而有所不同。数据分为训练集和测试集，要求数据分布均匀。数据是人工智能研究的基础。

1.1.4 人工智能三大学派

在人工智能发展过程中，根据研究方向和观点不同，被分为三大学派。

1.1.4.1 符号主义

符号主义认为人的认知基元是符号，智能是符号的表征和运算过程，计算机同样也是一个物理符号系统。符号主义主张（由人）将智能形式化为符号、知识、规则和算法，并用计算机实现符号、知识、规则和算法的表征和计算，从而实现用计算机来模拟人的智能行为。符号主义的代表方法为专家系统、知识图谱和决策树等。

1.1.4.2 连接主义

连接主义认为思维基元是神经元而不是符号处理过程，智能活动是由大量简单单元通过复杂连接后，并行运行的结果，可以通过人工方式构造神经网络，再训练人工神经网络产生智能。代表方法为神经网络、transformer 模型等。

1.1.4.3 行为主义

行为主义认为智能取决于感知和行为，取决于对外界复杂环境的适应，而不是表示和推理，不同的行为表现出不同的功能和不同的控制结构。人工智能可以沿和人类一样逐步进化。

1.2 生成式人工智能

1.2.1 概述

生成式人工智能(Generative Artificial Intelligence)是一种基于算法和模型生成文本、图片、声音、视频等技术，能学习并生成具有逻辑的新内容。其核心依赖于多模态模型。

1.2.2 发展历史

1.2.2.1 早期生成模型理论

20 世纪 50-80 年代，生成模型的基础理论被确立，主要着眼于概率模型等生成理论的研究。马尔科夫链和隐马尔科夫模型为生成式模型奠定了理论基础。

1.2.2.2 生成神经网络的发展

2014 年，变分自编码器和生成对抗网络等进步产生了第一个实用的深度神经网络，该网络能够针对图像等复杂数据学习生成模型，不仅输出影像的类别标签而且输出整个影像的模型。2017 年，Transformer 网络的发明使生成式模型取得长足进步。

1.2.2.3 生成式人工智能热潮

2020 年，OpenAI 发布了 GPT-3。2022 年末，ChatGPT 公开发布。其后各大企业、实验室都发布了自己的生成式人工智能，掀起了人工智能热潮。

1 课程内容总结

1.2.3 生成式人工智能产业

在生成式人工智能掀起热潮的现在，其产业链上中下游出现了百花齐放的趋势。产业链上游为基础层，包括数据、算力等软硬件产品；中游为模型层，根据应用领域的不同分为通用大模型和行业大模型两类；下游为应用层，生成式人工智能可产生包括文本、图片、音频、视频等在内的多种模态的内容，并应用于互联网、金融、教育、医疗、工业等领域。



图 1.1 生成式人工智能产业链

在 AI 大潮之下，生成式人工智能市场蓬勃发展。据第三方咨询机构统计数据，2022 年中国人工智能市场规模达到 2058 亿元。预计未来 5 年市场规模将保持 28.2% 的复合增长率，2027 年中国人工智能市场规模将达到 7119 亿元。




图 1.2 2017-2024 年中国人工智能市场规模预测趋势图

1.2.4 主要应用

1.2.4.1 文生图

文生图模型以自然语言描述为输入，输出与该描述相匹配的图像。它的开发始于 2010 年代中期，开始处于 GAN、自回归生成并行的探索阶段。随着深度神经网络技术的发展，2022 年至今，扩散模型占据主流，标志着模型的逐渐成熟。目前文生图商业化广泛着眼于 AI 作画、写真生成等应用。

1.2.4.2 文生视频

文生视频模型是一种机器学习模型，它使用自然语言描述作为输入，生成与输入文本相关的视频。目前高质量文本到视频生成的进展主要得益于视频扩散模型的发展。从 2016 年以前的图像拼接生成阶段、GAN/VAE 等生成阶段再到自回归模型与扩散模型生成阶段，生成质量得到了很大提高。

1.3 计算机视觉

1.3.1 概述

计算机视觉以看懂图像中的内容作为要解决的问题,是人工智能市场中的最大分支。它无论在技术成熟度、商业化进程还是市场增长速度、投资热度等方面一直都是人工智能领域最热门的行业之一。其任务包括图像生成、语义分割、目标检测以及图像分类等。

1.3.2 应用实例

1.3.2.1 图像分类

图像分类根据图像的语义信息将不同类型图像区分开来,在许多领域有广泛应用,包括安防领域人脸识别、交通领域的交通场景识别、医学领域的医学影像识别等。主要解决了“我是谁”的问题。

深度学习的图像分类方法是基于卷积神经网络模型的,利用图像像素信息作为输入,是端对端的训练框架,模型输出直接是图像识别的结果。

LeNet 模型被认为是最早的卷积神经网络模型。它由卷积层、池化层、全连接层的顺序连接每一层使用一个可微分的函数把激活数据层层传递,它开创性地利用卷积从图像中学习特征,节省了很多计算量。后来又出现了 AlexNet 模型,把 CNN 基本原理应用到很深很宽的网络中,使用了大量新技术,如 ReLU 激活函数、CUDA 加速等,采用双 GPU 协同训练,网络结构分为上下两层。其应用相较 LeNet 模型更加广泛。

1.3.2.2 目标检测

目标检测重点在于对图片进行分类的同时,检测物体的位置。主要需要采用图像分割等方法。相关应用包括自动驾驶、医学影像诊断和虚拟美妆等。

1.4 自动驾驶与智能网联汽车

1.4.1 概述

在经济危机推动、传感技术成熟、网络接入和信息处理能力大幅提高情况下,物联网技术得到发展。而把物联网的方法和技术应用到汽车交通行业,就得到了车联网。智能网联汽车是车联网的重要载体。

智能网联汽车,是指网联车与智能车的有机联合,搭载先进的车载传感器、控制器、执行器等装置,融合现代通信与网络技术,实现车与智能化的信息交换共享,目的是完成安全、节能、环保、高效、便携的行驶,并最终部分替代或完全替代人来操作的新一代汽车。

智能网联汽车的产业链是传统汽车产业链的升级与延伸,包括上游产业支撑、中游整车制造与解决方案、下游应用。

1.4.2 自动驾驶汽车分类

自动驾驶技术按照成熟度划分为六级,L0-L5。按照应用场景和实践特点可以分成五类：区域交通智能车辆、智能网联卡车、智能轿车、自动物流运输小车、轮式移动机器人。

在人工智能推进下，区域交通智能车辆已经实现无迹导航，导航精度大幅提高，无线通信广泛应用，智慧道路绿波通行。自动驾驶汽车在特定区域、约束环境下有较好接受度，具有区域最优性。目前辅助驾驶技术已经有很多有意义的实际应用，比如：军用越野侦察智能车辆、特定小区的区域交通智能车辆 CyberCars、助残智能车辆等。

智能网联卡车整体上主要以网联化应用为主、智能化重在智慧高速公路。它需要约束和规范高速公路的测试标准、在码头矿山等特殊领域与区域交通智能车辆有交叉。

1.4.3 典型应用场景

• 智慧公交应用

利用车路协同技术提升智能公交管理水平，沿公交专用道部署路侧单元RSU，可以实现公交专用道沿线的网络覆盖，形成智能公交车联网。公交车辆安装车载单元 OBU，交通信号控制系统可监测到公交车辆到达，为公交车辆提供信号优先服务。

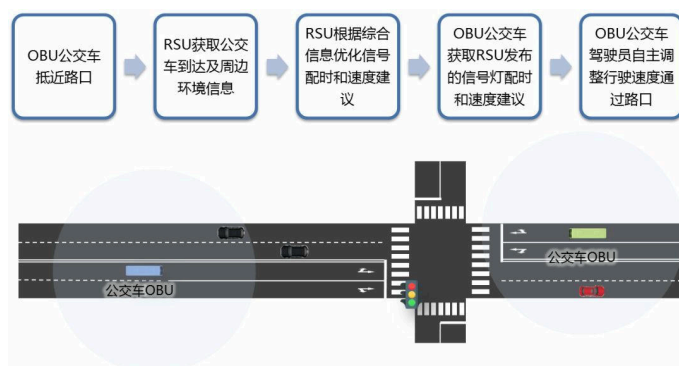


图 1.3 智慧交通应用

1.4.4 存在问题

(1) 全天候的感知技术不足。(2) 人机交互场景模糊。(3) 事故责任难以划分。(4) 排挤了出租车行业，影响就业。(5) 现有网络对智能网联汽车的通信支撑不足。

1.5 机器人

1.5.1 工业机器人

1.5.1.1 概述

在用工荒、产业升级背景下，面向工业领域的多自由度机器人应运而生。工业机器人是自动执行工作的机器装置，靠自身动力和控制能力实现各种功能。

工业机器人包括关节式、移动式和复合式。关节式机器人又分为串联、并联、SCARA 和直角坐标型。移动式机器人是无人车技术的原型，以载重、尺寸和续航的提升为重点关注方向。

目前国内工业机器人发展与国际差距较大，国内公司份额占比远低于世界工业机器人巨头。我国发展瓶颈包括减速机的材料、加工工艺、成本与可靠性不足；工业机器人仿真软件研发不到位，机器人控制系统不够完善等。

1.5.1.2 关键技术

工业机器人由传感器、本体、执行机构和示教器等组成。核心部件包括机器人本体、伺服系统、控制器和减速机。目前工业机器人前沿技术包括多机器人协作、人机交互、一体化控制等。

1.5.2 特种机器人

1.5.2.1 概述

除工业机器人之外，用于非制造业并服务于人类的机器人，如娱乐、军用、农业等，均为特种机器人。机器人具有生物功能的实际空间运行工具，能代替人类完成危险或者难以进行的劳作或者任务。对机器人的评价标准包括智能、机能和物理能等。

1.5.2.2 水下特种机器人

水下腐蚀、洋流、高压、感知困难等情况广泛存在。水下特种机器人主要用于海洋作战、海洋资源开发、海洋科考与水下应急救援。包括载人水下机器人、有缆水下机器人、自治水下机器人。核心指标主要为下潜深度、负载、感知、导航、动力定位和作业定位能力。

水下机器人以声波为主要感官，通过声呐进行通讯与探测。导航依托惯性导航和参照物导航。惯性导航以牛顿力学为基础，通过测量加速度并对时间积分、变换坐标系，获取速度、位置、偏航角等信息。参照物导航则是利用浮标等明确位置的参照物作为参考，通过自身传感器对参照物进行测量，并利用数据拟合完成定位。

1.6 智慧医疗

智慧医疗指在医疗中大量融入人工智能和信息化服务，提高医疗水平。智慧医疗服务于国家医疗卫生体系，目前用于智能组学、蛋白质预测、AI 药物设计、AI 医疗器械、手术机器人等领域。在此帮助下，中国成功研制了许多创新药，有效地降低了药品价格，审批时间大幅度减小。智慧医疗还作用于辅助诊断平台，使诊断诊疗规范化，通过大数据帮助智慧养老、预防疾病。

2 扩散模型

2.1 概述

DDPM (Denoising Diffusion Probabilistic Model), 简称扩散模型 (Diffusion Model), 在 2020 年被提出, 是一种新型的深度生成模型。它在诸多应用领域都有出色的表现, 如计算机视觉, NLP、波形信号处理、多模态建模、分子图建模、时间序列建模、对抗性净化等。尤其是在图像生成领域表现出了超越原模型 GAN 的优秀性能。近年来扩散模型出现大热趋势, Stability AI、OpenAI、Google Brain 等相继基于扩散模型提出的以文生图, 图像生成视频生成等模型。

扩散模型与其他研究领域有着密切的联系, 如稳健学习、表示学习、强化学习。

2.2 原理介绍

扩散模型和其他生成模型一样, 实现从噪声 (采样自简单的分布) 生成目标数据样本。它包括两个过程: 前向过程 (forward process) 和反向过程 (reverse process), 其中前向过程又称为扩散过程 (diffusion process)。基本思想是输入图像并通过一系列步骤, 逐渐向其添加高斯噪声^[1]。之后通过反转噪声过程来恢复原始数据, 训练神经网络。通过对逆向过程建模, 生成新数据。无论是前向过程还是反向过程都是一个参数化的马尔可夫链 (Markov chain), 其中反向过程可用于生成数据样本^[2]。




图 2.1 扩散模型工作流程

2.2.1 前向过程

前向过程的马尔可夫链称为前向链。前向链的作用是扰动数据, 它根据预先设计的噪声进度向数据逐渐加入高斯噪声, 直到数据的分布趋于先验分布, 即标准高斯分布^[1]。用 $x_0 \sim q(x_0)$ 表示原始数据及其分布, 则前向链的分布可由下式表达:

$$q(x_1, \dots, x_T | x_0) = \prod_{t=1}^T q(x_t | x_{t-1}) \quad (2.1)$$

$$q(x_t | x_{t-1}) = N(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t I) \quad (2.2)$$

这说明前向链是马尔可夫过程， x_t 是加入 t 步噪音后的样本， β_t 是事先给定的控制噪声进度的参数。当 $\prod_t(1 - \beta_t)$ 趋于 1 时， x_T 可以近似认为服从标准高斯分布^[2]。

当时间步长 $t = 500 < T$ 时我们要为采样 x_t 应用 q 函数 500 次。在此基础上，可以通过重参数化技巧，实现在任意时间步长下的可操作闭式采样。方差表同样可以作为 T 时间段的一个时间表获得更好的扩散效果。

2.2.2 逆向过程

逆向过程是去噪的过程，从给定的先验开始并使用参数化的高斯转换核，学习逐步恢复原数据分布。如果得到逆向过程 $q(x_{t-1}|x_t)$ ，就可以通过随机噪声 x_T 逐步还原出一张图像。DDPM 使用神经网络 $p_\theta(x_{t-1}|x_t)$ 拟合逆向过程 $q(x_{t-1}|x_t)$ 。当 β_t 很小时，逆向过程的转移核可以近似认为也是高斯的^[3]：

$$p_\theta(x_{0:T}) = P(x_T)\prod_{t=1}^T p_\theta(x_{t-1}|x_t) \quad (2.3)$$

$$p_\theta(x_{t-1}|x_t) = N\left(x_{t-1}; \mu_\theta(x_t, t), \sum_{\theta} \sigma_\theta(x_t, t)\right) \quad (2.4)$$

在实际情况中，我们不知道 $q(x_{t-1}|x_t)$ ，由于估计 $q(x_{t-1}|x_t)$ 需要涉及数据分布的计算，所以这是难以解决的。相反，我们用一个参数化的模型（例如一个神经网络）来近似 $q(x_{t-1}|x_t)$ 。由于 $q(x_{t-1}|x_t)$ 也将是高斯分布，对于足够小的 β_t ，我们可以选择是高斯的 p_θ ，只需对平均值和方差进行参数化即可逼近反向过程。

2.3 优势

同 GANs 相比，扩散模型具有更强的创意创造性。GAN 的有效输入都来自于人类投入的训练集，并且其底层架构也限制了 GAN 生成的内容实质上只是对现有内容无限地逼近模仿，无法实现真正的创造性突破。

相比之下，扩散模型在前向过程中每一步添加噪点，使图片变成毫无信息的噪点图片后再通过逆向过程除去噪点。这个过程中 AI 记录了构成一个图形的信息组成形式发生了有规律的转变，并通过这种转变方式创造出新的图像。因此，它可以在更好地模仿的基础上，厚积薄发地产生创新^[4]。

同时扩散模型还有训练目标直接预测噪声，避免了对抗训练的不稳定性；推导基于随机微分方程（SDE）和马尔可夫链，数学基础坚实；过随机采样噪声实现多样化生成，避免模式崩溃；兼容多模态与多任务，可无缝应用于图像、音频、视频、3D 等多种数据类型；通过逐步加噪-去噪学习数据本质特征，而非记忆训练样本，具有较高鲁棒性的优势。

2.4 应用

2.4.1 图像生成

扩散模型在图像生成中发挥了良好的性能，如图像超分辨率和修复（Image Super Resolution and Inpainting）、点云完成和生成（Point Cloud Completion and Generation）。

图像超分辨率旨在从低分辨率 (LR) 图像中恢复高分辨率 (HR) 图像，而图像修复则是重建图像中缺失或损坏的区域。超分辨率扩散(SRDiff)是基于扩散模型的单图像超分辨率模型，通过数据可能性的变分界限进行了优化。^[5] SRDiff 通过对带有马尔可夫链的 LR 输入的高斯噪声进行逐步变换，从而提供多样化和逼真的超分辨率结果^[6]。

3D 点云是用于捕获真实世界 3D 对象的 3D 表示的关键形式。然而，由于部分观察和自遮挡问题，现实世界中扫描的点云通常是不完整的。因此通过推理许多下游任务的缺失部分来恢复完整形状非常重要。扩散模型捕获了生成或完成问题的不确定性、多模态性质，从头或部分观察中采样并产生不同的形状。



图 2.2 对图片的超分效果

2.4.2 自然语言处理

自然语言处理（Natural language processing）旨在理解、建模和管理人类语言。其中文本生成的目的是在给定输入数据或随机噪声的情况下，用人类语言生成看似合理且可读的文本。利用扩散模型，研究人员开发了多种技术，如离散去噪扩散概率模型（D3PMs）为字符级文本生成引入了类似扩散的生成模型。他们通过超越具有均匀转移概率的腐败过程，推广了多项式扩散模型^[7]。

目前火热的大语言模型能够生成高质量的文本。为了在实际应用中可靠地部署这些 LM，文本生成过程通常是可控的，其在复杂的细粒度控制方面进展甚微。Diffusion LM 提出了一种基于连续扩散的新语言模型^[8]，从一系列高斯噪声矢量开始，并逐步使其成为与单词对应的矢量，有助于生成层次连续的隐式表示，实现复杂的控制。

2.4.3 多模态

扩散模型在多模态学习中也有重要应用。在文本到音频的生成领域，近年来提出了多种模型。Grad TTS 提出了一种新的文本到语音模型，该模型具有基于分数的解码器和扩散模型。它逐渐转换编码器预测的噪声，并通过单调对齐搜索方

法进一步与输入的文本对齐。DiffSound 提出了一种基于离散扩散模型的非自回归解码器，它在每个步骤中预测所有梅尔频谱符号，然后在以下步骤中细化预测的符号。EdiTTS 利用基于分数的文本到语音模型，在对梅尔谱图进行粗修改之前对其进行细化。ProDiff 通过直接预测干净数据，将去噪扩散模型参数化，而不是估计数据密度的梯度^[9]。

2.5 扩散模型的加速采样器

采样步骤繁多，生成速度慢，所需成本高是扩散模型的问题瓶颈所在。尽管基于隐空间的扩散模型在一定程度上缓解了该问题，但生成速度仍然较慢。因此加速采样器 DPM-Solver 应运而生^[10]。它能够基于 15 至 20 步的采样就能生成出媲美几百步生成效果的样本。

在 DPM-Solver 中，它基于常微分方程视角来去看待扩散模型。相比于从离散视角来看待扩散模型的 DDPM，Diffusion ODE 是从连续的视角来看待扩散模型，能够精确求解采样过程的每一步结果，从而实现采样的跳步而不影响样本生成精度从而实现生成速度的大幅提升^[11]。它尽可能地准确计算所有已知项，只对神经网络部分做近似，因此最大程度地减小了离散化误差。

2.6 未来展望

2.6.1 重新审视实际情况

目前，扩散模型中存在一些普遍相信的前提条件。但它们的绝对可靠性并未得到绝对确定。例如，人们普遍认为扩散模型的正向过程会将数据转换为标准高斯噪声。然而，前向扩散 SDE 的有限时间解仍然记得原始数据的分布。由于理想条件很难获得，因此，实际操作会导致不匹配的问题。我们应该认识到这种情况，并设计适当的扩散模型。

2.6.2 从离散时间到连续时间

由于扩散模型的灵活性，许多经验方法可以通过进一步分析得到加强。例如，研究发现，分析连续时间扩散模型可以获得更好的样本质量，因此可以将离散时间扩散模型转换为相应的连续时间扩散模型，然后对模型进行分析和设计。基于常微分方程视角的 DPM-Solver 正是这一研究领域的典型^[10]。

2.6.3 推广到复杂场景和更多研究领域

从计算机视觉到对抗性纯化，扩散模型已应用于七种不同类型的场景。然而，仍然存在一些未充分探索的场景，例如处理复杂的输入并生成多个输出，并在现实世界场景中获得更好的性能。同时，尽管现已在鲁棒学习、代表性学习和强化学习等一些研究领域对扩散模型进行了研究，扩散模型仍然存在与更多研究领域联系的机会。

3 课程感想

半学期的人工智能导论课程结束了，但是各位老师结合自身研究领域的介绍，让我在课程内初步接触到目前欣欣向荣的人工智能领域以及它的许多细分不同的研究方向。王老师和沈老师对人工智能的整体概述高屋建瓴，让我了解了人工智能的详细定义、发展历史与未来方向，深刻理解到无论哪个行业、哪个领域，历史的发展都是呈现螺旋上升机制的，总是在高潮-低潮再到高潮的反复中逐步实现进步与发展。

在自动驾驶与车路协同部分，张老师结合各种实际案例的讲解，让我对目前智能驾驶的发展水平也产生了深刻的理解。人工智能在许多领域超越了人类，大大提高了生产力。但同时我们也要看到，由于人工智能特殊的训练方法，许多时候它会在人类可以轻易完成的任务上犯下错误。例如车辆辅助驾驶功能与无人驾驶车发生了不少事故。这反映的是人工智能和人类智能目前仍然存在极大的互补关系，不能只肯定人工智能而否定人类智能，也不能只肯定人类智能而否定人工智能。要充分结合两者目前存在的优势与劣势，在细分领域上更好地发挥人工智能的辅助作用，实现生产力的提高和人类生活水平的提升。

在工业机器人部分，韩老师对机器人的综合讲解条理清晰。我在其中也深刻认识到目前国产工业机器人面临着许多瓶颈与挑战。市场份额远远不足世界巨头、工业仿真软件自研度低、效果不佳等问题，深深地制约着我国工业机器人领域的发展。这是一个我国科技领域的共性问题。必须要看到，目前我国在许多领域都未能达到世界一流乃至领先水平，面临着许多核心工艺的卡脖子问题。这些问题需要目前的科技工作者们共同奋斗努力，也需要作为下一代科技栋梁的我们做出新时期的贡献。这些已有的问题让我下定决心，要认真了解行业现状，学习专业细分领域知识，提高自主创新能力和科学研究能力，争取能进入高精尖科技发展行业，为解决国家科技卡脖子问题，建设科技强国贡献出自己的一份力量。

同时，老师们的讲解也让我认识到了在技术领域之外，资本运作、商业模式以及对接用户等领域对新科技的发展同样有重要作用。对此，我暗下决心，必须加深对消费端、应用端等层面的了解，争取从使用者的角度看待问题，从投资者的角度看待新科技与产品，从而不单止提高自身的技术水平，同时也逐步积累和提高把科技成果应用到实际生活的能力。

总而言之，半个学期的人工智能导论课程让我收获繁多。课程大大激发了我对人工智能领域的兴趣。我决定拿出空闲的娱乐时间认真学习人工智能的基础课程，如机器学习等，在人工智能导论课程的基础上逐渐对自己的知识网络进行延展，不断提高自身对人工智能的理解能力、认知程度与应用能力。课程展现的实验室的优秀成果和老师们散发的个人魅力，也让我对学院的科研项目产生了很大的憧憬。我想要好好学习专业课程，认真了解前沿领域，希望能以本科生的身份加入到课题组或实验室中学习和探索。

参考文献

- [1] HO J, JAIN A, ABBEEL P. Denoising Diffusion Probabilistic Models[J/OL]. ArXiv, 2020. <https://api.semanticscholar.org/CorpusID:219955663>.
- [2] SOHL-DICKSTEIN J N, WEISS E A, MAHESWARANATHAN N, et al. Deep Unsupervised Learning using Nonequilibrium Thermodynamics[J/OL]. ArXiv, 2015. <https://api.semanticscholar.org/CorpusID:14888175>.
- [3] NICHOL A, DHARIWAL P. Improved Denoising Diffusion Probabilistic Models[J/OL]. ArXiv, 2021. <https://api.semanticscholar.org/CorpusID:231979499>.
- [4] DHARIWAL P, NICHOL A. Diffusion Models Beat GANs on Image Synthesis[J/OL]. ArXiv, 2021. <https://api.semanticscholar.org/CorpusID:234357997>.
- [5] SAHARIA C, CHAN W, SAXENA S, et al. Photorealistic Text-to-Image Diffusion Models with Deep Language Understanding[J/OL]. ArXiv, 2022. <https://api.semanticscholar.org/CorpusID:248986576>.
- [6] LI H, YANG Y, CHANG M, et al. SRDiff: Single Image Super-Resolution with Diffusion Probabilistic Models[J/OL]. Neurocomputing, 2021, 479: 47-59. <https://api.semanticscholar.org/CorpusID:233476433>.
- [7] AUSTIN J, JOHNSON D D, HO J, et al. Structured Denoising Diffusion Models in Discrete State-Spaces[J/OL]. ArXiv, 2021. <https://api.semanticscholar.org/CorpusID:235755106>.
- [8] LI X L, THICKSTUN J, GULRAJANI I, et al. Diffusion-LM Improves Controllable Text Generation[J/OL]. ArXiv, 2022. <https://api.semanticscholar.org/CorpusID:249192356>.
- [9] NICHOL A, DHARIWAL P, RAMESH A, et al. GLIDE: Towards Photorealistic Image Generation and Editing with Text-Guided Diffusion Models[C/OL]//International Conference on Machine Learning. 2021. <https://api.semanticscholar.org/CorpusID:245335086>.
- [10] LU C, ZHOU Y, BAO F, et al. DPM-Solver: A Fast ODE Solver for Diffusion Probabilistic Model Sampling in Around 10 Steps[J/OL]. ArXiv, 2022. <https://api.semanticscholar.org/CorpusID:249282317>.
- [11] LU C, ZHOU Y, BAO F, et al. DPM-Solver: A Fast ODE Solver for Diffusion Probabilistic Model Sampling in Around 10 Steps[J/OL]. ArXiv, 2022. <https://api.semanticscholar.org/CorpusID:249282317>.
- [12] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]//NAVAB N, HORNEGGER J, WELLS W M, et al. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.