

人工智能背景下物理教学改革的思考与实践

杨菲宇 杨亚宏

(新疆理工职业大学通识学院, 新疆 图木舒克 843900)

摘要 人工智能的发展对人们的生活、学习和工作方式产生了深刻影响,也改变了科学研究的范式。同时,人工智能作为一种新质生产力,在方法论方面的突破,也为高校教育改革提供了新的机遇。本文探讨了人工智能背景下物理教学改革的思考,重点从计算方法的优化、实验教学与数据分析、跨学科融合和课程思政等方面,提出了具体的改革思路,以提升学生的实践创新能力,培养适应大数据和人工智能时代的高素质人才。

关键词 教学改革;人工智能;实验教学

REFLECTIONS AND PRACTICES ON PHYSICS EDUCATION REFORM IN THE ERA OF ARTIFICIAL INTELLIGENCE

YANG Feiyu YANG Yahong

(School of General Education, Xinjiang Vocational University of Technology, Tumxuk, Xinjiang 843900)

Abstract The rise of artificial intelligence (AI) has profoundly reshaped how people live, learn, and work, and it is transforming the paradigms of scientific research. As a new form of productive force, AI's methodological breakthroughs also create fresh opportunities for higher-education reform. This paper explores the rethink of physics teaching in the AI era, proposing concrete reform ideas that center on optimizing computational methods, integrating experimental instruction with data analytics, promoting interdisciplinary convergence, and embedding ideological and political elements into the curriculum. These measures aim to enhance students' practical and innovative capabilities and to cultivate high-caliber talent suited to the age of big data and artificial intelligence.

Key words teaching reform; artificial intelligence; experimental teaching

1 人工智能新突破

进入 20 世纪,随着计算机技术的飞速发展,数值模拟逐渐成为应对复杂物理问题的重要工具。有限元法(Finite Element Method, FEM)、蒙特卡罗模拟(Monte Carlo Simulation, MCS)和密度泛函理论(Density Functional Theory,

DFT)等数值方法被广泛应用于物理研究,通过大规模数值求解为模拟和预测复杂系统的行为提供了有力支持。例如,FEM 在结构力学、电磁场分析与流体力学中具有重要应用^[1,2];MCS 常被用于统计物理与量子力学的计算^[3,4];而 DFT 则成为计算化学与材料科学中的核心工具^[5,6]。然而,随着研究对象的日益复杂,这些传统数值方法在处理高维系统、稀疏数据和不确定边界条件时,逐

收稿日期: 2025-01-31

基金项目: 新疆生产建设兵团本科教育教学改革研究重点项目(BTBKXM-2025-Z57)。

通信作者: 杨亚宏, yangyahong369@gmail.com。

引文格式: 杨菲宇, 杨亚宏. 人工智能背景下物理教学改革的思考与实践[J]. 物理与工程, 2025, 35(6): 125-132.

Cite this article: YANG F Y, YANG Y H. Reflections and practices on physics education reform in the era of artificial intelligence[J]. Physics and Engineering, 2025, 35(6): 125-132. (in Chinese)

渐显现出以下不足:首先,计算成本高昂,例如在三维复杂流体力学等问题中,系统规模的指数级增长往往导致大量资源的消耗;其次,数值模拟依赖理想化模型与边界条件,难以有效描述现实系统中的不确定性,尤其在高压、高温等极端环境下,实验数据的稀缺性导致模型精度受限;最后,迭代求解过程耗时且效率低下,容易陷入局部最优,难以满足实时预测和快速决策的需求。

进入 21 世纪,大数据、机器学习与深度学习的迅猛发展标志着“第四范式”——数据驱动的科学研究——的兴起^[7]。特别是自 2022 年 11 月生成式人工智能(Generative Artificial Intelligence, GAI)的问世,引发了新一轮的科技浪潮。到 2024 年,物理学诺贝尔奖颁发给人工神经网络和机器学习,进一步凸显了人工智能在物理学科研究中的潜力。与传统的理论与实验方法不同,人工智能依托其强大的数据处理与模式识别能力,为科学研究提供了全新的技术与思路,其在物理学领域的应用日益广泛,并已取得一系列突破性成果。

1) 在复杂物理系统的建模与预测方面,人工智能展现出卓越的效率与精度

以凝聚态物理和材料科学为例,清华大学研究团队开发的 DeepH 模型^[8-10]将机器学习与第一性原理计算相结合,利用材料数据库数据直接预测密度泛函理论的核心物理量——哈密顿量,从而绕过了传统 DFT 耗时的自洽求解过程。该方法在保持高精度的同时,大幅提升了计算效率。这不仅加速了新材料的发现进程,也揭示了人工智能在理解复杂物理现象方面的巨大潜力。

2) 在新物理规律的探索与验证方面,人工智能同样提供了革命性的思路

加州理工学院的研究团队通过深度学习模型分析海量天体物理数据,成功识别出暗物质分布特征^[11];瑞士联邦理工学院的物理学家则运用机器学习算法,基于行星运行的历史数据,自动生成了符合开普勒定律^[13]与牛顿万有引力定律的轨道模型^[12]。这些研究不仅验证了机器学习在物理规律发现中的潜能,也为天文学与宇宙学研究提供了新的思路和方法。

3) 在加速物理计算与优化求解方面,新型人工智能算法展现出独特优势

以物理信息神经网络(Physics-Informed Neural Networks, PINNs)为代表的方法^[14],通过

将物理定律与约束条件以损失函数的形式融入神经网络,能够高效求解复杂的偏微分方程(Partial Differential Equations, PDEs)。例如,中国人民大学的研究团队提出了改进的 PINN 模型——PeRCNN(Physics-encoded Recurrent Convolutional Neural Network)^[15],结合卷积神经网络(Convolutional Neural Network, CNN)与循环神经网络(Recurrent Neural Network, RNN)的优势,在高维反应—扩散方程问题中不仅获得了高精度解,还展现出优异的外推能力。这种方法在处理不规则域及复杂边界条件时,依然能够保持高效稳定,相较于传统网格划分的数值方法,大幅降低了计算量并提高了灵活性。

4) 在大规模与高维度实验数据的分析中,人工智能算法同样表现出色

哈佛大学的天文学家利用 CNN 对哈勃太空望远镜获取的海量观测数据进行自动识别和筛选,发现了多颗潜在的系外行星候选体^[16];欧洲核子研究中心(CERN)则借助 RNN 对大型强子对撞机产生的庞大数据集进行分析,成功识别出希格斯玻色子信号^[17]。与传统统计模型相比, RNN 能够从时间序列数据中自动提取复杂特征,减少对人为参数和物理假设的依赖,从而使信号识别更加高效且准确。

为加快人工智能技术在教育领域的应用并深化其与学科的融合,我国先后发布了《高等学校人工智能创新行动计划》等相关政策^[18,19]。物理学作为基础科学的重要组成部分,需不断引入人工智能方法与技术,不仅能提升学生在数据分析、数值模拟和模型构建等方面的能力,还能增强其科研创新能力,顺应大数据与人工智能时代的发展需求。

在人工智能时代,物理学的研究范式正经历深刻变革。在理论推导与实验验证基础之上,以数据驱动和智能计算为代表的新方法论正在崛起,二者深度融合,共同拓展着物理学探索的边界。这对物理专业的教学内容和人才培养目标提出了全新的要求。然而,传统的物理教学多侧重于经典理论与数值方法,较少引入机器学习、深度学习等人工智能技术,难以充分反映当前物理学科的前沿发展趋势。因此,物理教学改革亟须更新教学理念、教学内容和教学方法。

2 物理教学中引入人工智能案例

2.1 引入人工智能优化传统计算方法

随着人工智能技术的迅猛发展,物理信息神经网络^[14]在求解 PDEs 方面展现出独特优势。我们在“计算物理”课程中增加了 PINNs 教学模块,从而提高了学生解决复杂物理问题的能力。通过“传统数值方法与机器学习方法”对比的教学方法,学生在深入理解 PDEs 离散与网格划分的基础上,使用 pytorch 深度学习框架构建和训练 PINNs,成功获得了与解析解和数值解相一致的结果。

在教学实施中,为了让学生深入地理解 PINNs 在处理复杂、高维问题时的性能特点,我们将其应用于求解一个经典的高维、非线性流体力学问题——三维非定常 Navier-Stokes (NS) 方程。NS 方程是描述粘性不可压缩流体运动的基本方程,其形式如下

$$\begin{cases} \frac{\partial \mathbf{u}}{\partial t} + (\mathbf{u} \cdot \nabla) \mathbf{u} = -\nabla p + \frac{1}{\text{Re}} \nabla^2 \mathbf{u} \\ \nabla \cdot \mathbf{u} = 0 \end{cases}$$

该方程的参考解如下,其中 $\text{Re}=1, a=1, d=1$

$$\begin{aligned} u(x, y, z, t) &= -a[e^{ax} \sin(ay + dz) + e^{az} \cos(ax + dy)]e^{-d^2 t} \\ v(x, y, z, t) &= -a[e^{ay} \sin(az + dx) + e^{ax} \cos(ay + dz)]e^{-d^2 t} \\ w(x, y, z, t) &= -a[e^{az} \sin(ax + dy) + e^{ay} \cos(az + dx)]e^{-d^2 t} \\ p(x, y, z, t) &= -\frac{1}{2}a^2[e^{2ax} + e^{2ay} + e^{2az} + 2\sin(ax + dy)\cos(az + dx)e^{a(y+z)} + 2\sin(ay + dz)\cos(ax + dy)e^{a(z+x)} + 2\sin(az + dx)\cos(ay + dz)e^{a(x+y)}]e^{-2d^2 t} \end{aligned}$$




图1 神经网络求解 NS 方程原理图

在本案例中,学生通过深度学习框架内置的自动微分功能,将上述方程的残差(residual)以及边界与初值的损失项共同纳入神经网络的损失函数,进而在训练过程中最小化神经网络参数,使其逐步逼近满足物理约束的解,其原理如图1所示。我们构建了一个包含4个隐藏层、每层50个神经元的全连接网络,使用 Tanh 作为激活函数。在时空域内随机采样5000个点用于评估物理方程残差,在边界和初始时刻分别采样5000个点用于施加边界和初始条件。在 NVIDIA GeForce RTX 4070 GPU 上,使用 DeepXDE 框架对模型进行训练,整个训练过程包括3000个 Adam 迭代周期和 L-BFGS 优化^[14,15]。

为了客观评估 PINN 的性能,我们同时采用传统的有限差分法(Finite Difference Method, FDM)对同一问题进行求解。FDM 的实现基于一个 $51 \times 51 \times 51$ 的均匀空间网格,并采用显式欧拉格式进行时间推进,时间步长 $\Delta t = 1 \times 10^{-4}$,总计迭代10000步以完成 $T=1.0$ 的模拟。结果的对比呈现在图2与表1中。图2每一组图从上至下分别为 PINN 预测解、FDM 数值解和解析解,从左至右的时间点为 $t=0, 0.2, 0.4, 0.6, 0.8, 1.0$ 。从图中可以看出, PINN 的解在整个求解周期内与解析解高度吻合,其精度与经典的 FDM 方法相当,直观地验证了 PINN 处理复杂物理问题的有效性。我们计算了两种方法在不同时刻相对于解析解的相对 L2 范数误差。结果显示, FDM 在整个求解域内表现出极高的精度,其误差维持在 10^{-4} 量级。PINN 的误差虽然略高(在 $10^{-4} \sim 10^{-3}$ 量级之间),但其预测值在数量级上依然是准确的。这一对比教学环节,让学生清晰地认识到不同计算方法的特点:经典的 FDM 在网格规则的


图2 三维 NS 方程在不同时刻的速度场分量(u, v, w)对比

表 1 PINN 与 FDM 求解三维 NS 方程的性能对比

比较维度	PINN	有限差分法
实现方式	无网格;直接将 PDE 编码进损失函数,实现简单	基于网格;需手动进行空间和时间离散,实现复杂,尤其在处理复杂几何边界时
求解性质	获得整个时空域的连续解析解,可在任意时空点进行推理,精度均匀	获得离散网格点上的数值解,非网格点上的值需插值得到,存在插值误差
计算耗时	前期训练耗时较长。本例中,训练总耗时约 20 分钟。但训练完成后,推理速度极快	每个时间步计算快,但总耗时随时间步数线性增长。本例中,模拟到 $T=1.0$ (10000 个时间步),总耗时约 31 分钟
内存占用	内存主要用于存储网络权重和训练中的梯度,与网络规模和批处理大小相关,与求解时长无关	内存主要用于存储整个计算域在当前时刻的物理场 ($51^3 \times 4$ 个浮点数),内存需求随网格密度立方增长

情况下能够达到非常高的计算精度,而 PINN 则在无需划分网格的前提下,以较高精度成功复现了复杂的物理过程。这直观地验证了 PINN 处理复杂物理问题的有效性,并引发了学生对于精度、效率和实现复杂度之间权衡的深入思考。

此外,函数拟合在物理计算与实验数据分析中同样至关重要。传统方法(如拉格朗日插值、多项式拟合与样条插值)在处理低维且光滑的数据时较为有效,但在面对高维、非线性或含噪数据时,往往会出现过拟合或振荡问题,从而导致模型精度下降。神经网络则通过非线性激活函数与优化算法,能够逼近任意复杂的函数关系,对非线性模式具有较强的适应性与鲁棒性,更易处理高维输入。因此,在“计算物理”课程中引入机器学习的函数拟合模块,帮助学生掌握基于神经网络的高维数据拟合方法,进而提升其数据处理与模型构建的能力,为其在大数据与人工智能时代的科研创新奠定坚实基础^[20]。

2.2 强化实验教学与提升数据分析能力

物理学是一门以实验为基础的科学,实验数据的采集与分析贯穿于整个研究过程。然而,传统实验课程往往侧重于基本的实验操作和理论验证,较少涵盖数据分析的深度挖掘与前沿技术^[21,22]。在大数据与人工智能迅猛发展的背景下,实验数据分析能力已成为物理专业学生必备的关键技能。因此,教学改革的重点已放在帮助学生掌握利用人工智能进行数据处理的方法,以更好地适应未来科研与实践的需求。

为此,我们在实验教学中以单缝衍射实验为例,引入了机器学习技术,以提升数据分析的深度与准确性。具体做法如下:首先,利用高分辨率相

机或光电探测器获取光屏上不同位置的光强数据。实验采集的原始数据如图 3 中灰色点所示,其中横轴为光屏上的位置(单位:毫米),纵轴为光强(CCD 输出为电压值,与光强成正比,单位:伏特)。当位置在约 18mm 附近时,出现中央主级最大亮纹,其余级的亮纹信号受噪声影响明显。我们引导学生对比了三种不同的降噪方法:传统的移动平均滤波、Savitzky-Golay(SG)滤波,以及深度学习驱动的降噪自编码器(Denoising Autoencoder)。利用 PyTorch 的 DataLoader 以 64 为批处理大小进行数据加载。该模型由一个对称的编码器和解码器构成:编码器通过一个(1-256-128-8)的全连接网络结构,将一维的位置信息压缩至一个 8 维的潜空间;解码器则通过一个(8-128-256-1)的逆向结构,从潜向量中重建光强信号。网络的所有隐藏层均采用 Tanh 作为激活函数,而输出层则不设激活函数,以保证输出值的动态范围不受限制。在训练阶段,模型以均方误差(MSE)为损失函数,并采用学习率为 10^{-3} 的 Adam 优化器进行参数优化。为了防止过拟合,我们还引入了值为 10^{-5} 的 L2 正则化(weight decay),并对模型进行了 2000 个周期的充分训练,直至损失函数收敛。

如图 3 所示,我们对比了三种方法的降噪效果。实验结果表明,自编码器滤波在噪声抑制与衍射特征保留方面均优于其他两种方法。与平移平均滤波相比,自编码器能够更有效地去除复杂噪声,而不会模糊数据的关键特征;与 SG 滤波相比,自编码器在处理非线性与高维数据时展现出更高的适应性与准确性。降噪自编码器为物理实验数据处理提供了新的思路与工具,通过在教学




图3 使用自编码器和其他两种方法降噪的比较

中使用自编码器滤波,结合传统与现代技术手段,向学生展示了大数据与人工智能工具在解决经典物理问题时的潜能,从而激发了学生在前沿技术与科研创新上的探索热情。

2.3 推动跨学科融合,培养创新科研能力

随着人工智能技术的普及,物理学已与计算机科学、数据科学以及化学和材料科学等领域实现了深度融合。未来的物理研究不仅要求扎实的专业知识,还需具备跨学科的视野与创新能力。因此,物理专业的教学改革更加注重跨学科素养的培养,以拓展学生的知识面,增强他们在科研项目中的综合竞争力。为此,我们将大学生创新项目与创新创业比赛作为锻炼学生跨学科能力的关键途径。

在实践中,我们选取马里兰大学提供的锂电池数据^[23]作为教学与科研相结合的案例,开展了基于多层感知器(Multi-Layer Perceptron, MLP)神经网络的电池循环寿命预测研究。学生团队在收集并预处理数据后,搭建并训练了MLP模型,分析了影响电池寿命的复杂非线性因素,并预测了锂电池在多次充放电循环后的使用寿命。图4所示的灰色点代表实际循环寿命数据,灰色曲线则为MLP模型的预测结果。可以观察到,灰色预测曲线与实际数据高度吻合,表明MLP在锂电池循环寿命预测中表现出较高的准确度与可靠性。

除此之外,我们还选取了生物物理领域的AlphaFold模型^[24]作为案例,让学生了解其如何利用深度神经网络与进化信息,从氨基酸序列预测蛋白质的三维结构。学生通过探究氨基酸间的相互作用和蛋白质折叠动力学,深入理解结构预测背后的物理机制,并将预测出的蛋白质结构应用




图4 MLP神经网络预测锂电池循环寿命结果

于药物靶点识别、酶工程等实际场景。这种以问题为导向的学习方式,不仅加深了学生对生物物理与人工智能交叉领域的认识,也培养了他们将所学知识应用于多学科背景下科研实践的能力。

2.4 人工智能背景下课程思政的融入

在人工智能与物理学深度融合的教学背景下,物理课程不仅关注学生的专业素养,也融入了思政元素,从而培养学生的科学素养与社会责任感^[25,26]。基于此,我们在教学改革中从两个方面将思政教育融入专业教学。

1) 从“科学范式演变”到“创新发展理念”

物理学的发展历程是人类探索自然规律、认知世界的科学实践,折射出研究范式的不断革新。通过回顾物理学研究范式的演变过程,引导学生正确理解事物发展的内在规律,树立科学的世界观与方法论。同时,学生了解了从实验验证、理论推导、计算模拟到数据驱动的研究手段演变,掌握了各阶段方法的优缺点,培养了批判性思维和针对不同问题选用合适方法的能力。

在此过程中,我们结合了我 国近年来在科技

创新方面取得的重大成果,如量子通信领域的突破,彰显了新时期“创新发展”理念对国家与学科的深远影响。通过这些案例,既激发了学生的民族自豪感,也引导他们思考如何利用人工智能技术推动物理学的进一步发展,从而培养了学生为国家科技创新贡献力量的责任担当。

2) 发扬团队合作与协同创新精神

随着人工智能与物理学结合的日益深入,现代物理研究在很大程度上依赖跨学科、跨领域的协同创新。为帮助学生切身感受到团队合作的重要性,我们将我国在科技创新领域的突破案例融入教学,例如 EAST 核聚变装置(“人造太阳”)等重大项目,生动展现了跨学科协作与团队合作对科研进展的巨大推动作用。

通过这些案例,学生不仅认识到团队合作与协同创新在科学研究中的关键作用,还在潜移默化中树立了服务国家、投身科研的爱国主义精神。进一步地,他们更深刻地理解到,在人工智能时代,独立研究已难以有效应对复杂问题,唯有通过协同创新和跨学科合作,才能在重大科研项目中取得真正的突破。

3 结语

人工智能技术的迅猛发展正深刻地影响着物理学的研究范式和教育模式。在人工智能背景下推进物理教学改革,不仅是顺应时代发展的必然选择,更是培养具备创新能力和跨学科素养的高素质人才的重要途径。通过在教学引入人工智能技术,强化学生的数据分析和实践能力,优化传统计算方法,推动跨学科融合,并融入课程思政教育,能够全面提升学生的综合素质和科研创新能力。

人工智能在物理教学中的应用仍具广阔潜能。随着深度学习、强化学习等算法的不断演进,可持续优化数据处理与模型训练方案,提升对实验数据、仿真结果的分析效率。在更多维度与复杂情境中探索算法性能,将有助于拓展物理教学的深度与广度,为学生提供更加精准的知识呈现与多元化的实践机会。与此同时,深入挖掘人工智能与物理学科的契合点,可推动教学内容与研究前沿之间的衔接,让学生在掌握基础理论的同时,也能敏锐感知技术发展趋势。

只有通过持续的创新和探索,物理教学才能不断适应时代的发展需求,培养出引领未来科技进步的优秀人才。这不仅有助于推动物理学科的持续进步,也将为国家的科技创新和社会发展作出更大的贡献。

参 考 文 献

- [1] JALILI B, JALILI P, PASHA P, et al. The magneto-hydrodynamic flow of viscous fluid and heat transfer examination between permeable disks by AGM and FEM method [J]. SSRN Electronic Journal, 2023.
- [2] DENG E F, WANG Y H, ZONG L, et al. Seismic behavior of a novel liftable connection for modular steel buildings: Experimental and numerical studies [J]. Thin-Walled Structures, 2024, 197.
- [3] HERMANN J, SCHAETZLE Z, NOE F. Deep-neural-network solution of the electronic Schrödinger equation [J]. Nature Chemistry, 2020, 12(10): 891.
- [4] SALAHSHOORI I, JORABCHI M N, GHASEMI S, et al. Advancements in wastewater treatment: A computational analysis of adsorption characteristics of cationic dyes pollutants on amide functionalized-MOF nanostructure MIL-53 (Al) surfaces [J]. Separation and Purification Technology, 2023: 319.
- [5] MANCUSO J L, MROZ A M, LE K N, et al. Electronic structure modeling of metal-organic frameworks [J]. Chemical Reviews, 2020, 120(16): 8641-8715.
- [6] YU L, ZHANG T Y, LIN Y C, et al. Graphene and beyond: Recent advances in two-dimensional materials synthesis, properties, and devices [J]. ACS Nanoscience, 2022, 2(6): 450-485.
- [7] JORDAN M I, MITCHELL T M. Machine learning: Trends, perspectives, and prospects [J]. Science, 2015, 349(6245): 255-260.
- [8] LI H, TANG Z, GONG X, et al. Deep-learning electronic-structure calculation of magnetic superstructures [J]. Nature Computational Science, 2023: 321-327.
- [9] 李贺,段文晖,徐勇.深度学习与第一性原理计算 [J]. 物理, 2024, 53(7): 442-449.
LI H, DUAN W H, XU Y. Deep learning and first-principles calculation [J]. Physics, 2024, 53(7): 442-449. (in Chinese)
- [10] TANG Z, LI H, LIN P, et al. A deep equivariant neural network approach for efficient hybrid density functional calculations [J]. Nature Communications, 2024, 15: 8815.
- [11] DELOS RIOS M, PETAC M, ZALDIVAR B, et al. Determining the dark matter distribution in simulated galaxies with deep learning [J]. Monthly Notices of the Royal Astronomical Society, 2023, 5254: 6015-6035.

- [12] CASTELVECCHI D. AI Copernic ‘discovers’ that Earth orbits the Sun[J]. *Nature*, 2019, 575(7782): 266-267.
- [13] 高健,李宛豫,张陆峰,等. 人工智能驱动的物理学研究——以开普勒行星运动椭圆定律为例[J]. *物理与工程*, 2024, 34(5):198-203.
GAO J, LI W Y, ZHANG L F, et al. Artificial intelligence driven physics research: Taking Kepler’s elliptical law of planetary motion as an example[J]. *Physics and Engineering*, 2024, 34(5): 198-203. (in Chinese)
- [14] RAISSI M, PERDIKARIS P, KARNIADAKIS G. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. *Journal of Computational Physics*, 2019, 378: 686-707.
- [15] JIN X, CAI S, LI H. NSFnets (Navier-Stokes flow nets): Physics-informed neural networks for the incompressible Navier-Stokes equations [J]. *Journal of Computational Physics*, 2020, 426: 109951.
- [16] RAO S, MAHABAL A, RAO N, et al. Nigraha: Machine-learning-based pipeline to identify and evaluate planet candidates from TESS[J]. *Monthly Notices of the Royal Astronomical Society*, 2021, 502: 2845.
- [17] CASTELVECCHI D. Quantum machine goes in search of the Higgs boson[J]. *Nature*, 2017, 530: 1476-4687.
- [18] 中华人民共和国教育部. 教育部关于印发《高等学校人工智能创新行动计划》的通知[EB/OL]. http://www.moe.gov.cn/srcsite/A16/s7062/201804/t20180410_332722.html, 2024-05-15.
Ministry of Education of the People’s Republic of China. Notice on the issuance of the Artificial Intelligence Innovation Action Plan for Higher Education Institutions[EB/OL]. (2018-04-02)[2024-05-15]. http://www.moe.gov.cn/srcsite/A16/s7062/201804/t20180410_332722.html. (in Chinese)
- [19] 国务院. 国务院关于印发新一代人工智能发展规划的通知[EB/OL]. https://www.gov.cn/zhengce/content/2017-07/20/content_5211996.htm, 2024-05-15.
State Council of the People’s Republic of China. Notice on the issuance of the New Generation Artificial Intelligence Development Plan[EB/OL]. (2017-07-08)[2024-05-15]. https://www.gov.cn/zhengce/content/2017-07/20/content_5211996.htm. (in Chinese)
- [20] TENACHI W, IBATA R, DIAKOIANNIS F I. Deep Symbolic Regression for Physics Guided by Units Constraints: Toward the Automated Discovery of Physical Laws[J]. *The Astrophysical Journal*, 2023, 959: 1-20.
- [21] 姜涛,孙艳,于华民. 人工智能在大学物理教学中的应用[J]. *创新教育研究*, 2024, 12(5): 423-430.
JIANG T, SUN Y, YU H M. Application of artificial intelligence in college physics teaching[J]. *Innovation Education Research*, 2024, 12(5): 423-430. (in Chinese)
- [22] 姜涛,刘兵. 基于人工智能技术的智能化物理实验教学[J]. *创新教育研究*, 2024, 12(6): 540-546.
JIANG T, LIU B. Intelligent physics experiment teaching based on artificial intelligence technology[J]. *Innovation Education Research*, 2024, 12(6): 540-546. (in Chinese)
- [23] Center for Advanced Life Cycle Engineering (CALCE). Battery Data[EB/OL]. <https://calce.umd.edu/battery-data>, 2024-12-28.
- [24] ABRAMSON J, ADLER J, DUNGER J, et al. Accurate structure prediction of biomolecular interactions with AlphaFold 3[J]. *Nature*, 2024, 630: 493-500.
- [25] 周诗韵,岑刻,乐永康. 实验课程中激发学生探究仪器科学热情的案例[J]. *物理与工程*, 2021, 31(5):124-128.
ZHOU S Y, CEN Y, LE Y K. Cases of stimulating students’ enthusiasm for exploring instrument science in experimental courses[J]. *Physics and Engineering*, 2021, 31(5): 124-128. (in Chinese)
- [26] 李平,尹超. 人工智能背景下大学生通识课程的教学探索与实践创新[J]. *大学化学*, 2024, 39(10):402-407.
LI P, YIN C. Teaching exploration and practice innovation of general courses for college students under the background of artificial intelligence[J]. *University Chemistry*, 2024, 39(10): 402-407. (in Chinese)
- (上接第 124 页)
- ZHOU J M. Scientific writing and typesetting[M]. Xi’an: Northwestern Polytechnical University Press, 2024. (in Chinese)
- [6] TANTAU T, WRIGHT J, MILETIC V. The beamer class User Guide for version 3. 76 [Z/OL]. (2025-08-13). <https://tug.ctan.org/macros/latex/contrib/beamer/doc/beameruserguide.pdf>
- [7] PHILIP K, MORITZ W, PHILIPP L. The biblatex Package: Programmable Bibliographies and Citations[Z/OL]. (2025-07-10). <https://mirrors.zju.edu.cn/CTAN/macros/latex/contrib/biblatex/doc/biblatex.pdf>
- [8] 朱家乐. 基于 Gitee 平台的软件实训课程分组教学设计与实践[J]. *电脑知识与技术*, 2023, 19(10): 105-107.
ZHU J L. Design and implementation of group-based teaching for software practical training courses using the Gitee platform[J]. *Computer Knowledge and Technology*, 2023, 19(10): 105-107. (in Chinese)