

基于生成式编程工具的机器学习课程 混合式教学改革实践

王朔遥 毕宿志 聂晨 全智

深圳大学电子与信息工程学院, 深圳 518060

摘要 随着大模型技术与生成式编程工具的快速发展, 高校《机器学习》课程中以“知识讲授—代码实现”为主的传统教学模式逐渐暴露出对学生高阶认知能力与综合问题解决能力培养不足的问题。以深圳大学电子与信息工程学院本科《机器学习》课程为研究对象, 本文围绕生成式编程工具广泛应用背景下人才培养需求的变化, 探索通过混合式教学改革推动课程教学目标由“算法与技能训练”向“复杂问题解决能力培养”转型的实施路径。改革从教材与知识体系更新、教学组织机制重构、项目制探索型学习设计以及多维度综合评价体系构建等方面展开, 形成了教师—助教—学生协同参与的混合式教学模式。通过课程实践与教学案例分析表明, 该改革有效提升了学生在问题建模、模型选择、参数分析与系统表达等方面的综合能力, 增强了其科研兴趣与创新意识。研究结果对生成式智能工具背景下理工科课程的教学改革具有一定的借鉴意义。

关键字 生成式编程工具, 机器学习, 混合式教学, 课程改革, 问题解决能力

Blended Teaching Reform and Practice of the Machine Learning Course in the Context of Generative Programming Tools

Wang Shuoyao Bi Suzhi Nie Cheng Quan Zhi

College of Information and Electronics Engineering
Shenzhen University
Shenzhen 518060, China

Abstract—With the rapid development of large-scale models and generative programming tools, the traditional teaching paradigm of “knowledge delivery – code implementation” in machine learning education has become increasingly inadequate for cultivating students’ higher-order cognitive and problem-solving abilities. Taking the undergraduate Machine Learning course at Shenzhen University as a case study, this paper explores a blended teaching reform aimed at shifting the course objective from skill-oriented training toward the cultivation of comprehensive problem-solving capabilities in the context of the widespread adoption of generative programming tools. The reform is implemented from four perspectives: curriculum and textbook renewal, teaching mechanism restructuring, project-based exploratory learning, and a multidimensional evaluation system. A collaborative blended teaching framework involving instructors, teaching assistants, and students is established. Teaching practice and case analysis demonstrate that the proposed reform effectively enhances students’ abilities in problem modeling, method selection, parameter analysis, and systematic expression, while also strengthening their research interest and innovative awareness. The proposed approach provides valuable references for teaching reform in other science and engineering courses under the generative AI paradigm.

Keywords—Generative programming tools, machine learning, blended learning, curriculum reform, problem-solving

1 引言

《机器学习》课程是人工智能与数据科学专业的核心基础课程, 旨在帮助学生系统掌握机器学习的基本概念、方法与工具, 理解其在智能系统设计与数据驱

动决策中的作用。随着大数据与深度学习的迅猛发展, 机器学习技术已广泛应用于图像识别、自然语言处理、智能推荐等多个领域, 对社会科技进步和产业创新产生了深远影响^{[1][2]}。习近平总书记指出, 加快发展新一代人工智能是推动我国科技跨越发展和产业优化升级的重要战略抓手, 并强调人工智能作为引领科技革命和产业变革的战略性技术, 具有强大的带动效应。因此, 扎实的机器学习训练, 是培养具有创新精神与工程能力的人工智能高水平人才的基础。

* **基金资助**: 广东省高等教育教学改革建设项目 (839/0000027307, 839/0000027228), 深圳大学教学改革研究项目 (JG2025066, JG2023015)。

* * 通讯作者: 毕宿志 bsz@szu.edu.cn

近年来,随着生成式人工智能与编程辅助工具(如 ChatGPT、GitHub Copilot 等)的快速普及,学生在代码生成与调试环节的门槛显著降低,传统教学体系逐渐暴露出适应性不足的问题:一方面,教学内容滞后于学科前沿,未能有效反映大模型时代下的知识结构;另一方面,学生学习模式趋于被动,对问题建模、算法分析与结果表达等高阶能力的训练不足,难以支撑其未来科研与工程实践能力的持续成长。

为了顺应人工智能技术快速发展和生成式编程工具广泛应用的时代背景,提升学生综合问题解决能力、培养具备工程实践与创新意识的复合型人才,近年来高校课堂中围绕“能力导向”的教学改革逐渐成为研究热点^{[3][4][5]}。在此背景下,深圳大学电子与信息工程学院面向本科生开设的《机器学习》课程,作为人工智能相关专业的重要核心课程,其教学目标和教学模式正面临新的挑战与机遇。传统《机器学习》课程往往侧重算法原理讲解和模型实现训练,强调对经典算法流程和编程技能的掌握,在一定程度上忽视了复杂工程问题情境下模型选择、问题建模与结果分析等高阶能力的培养。

随着生成式编程工具在教学与学习过程中的普及,学生获取代码实现与算法示例的门槛显著降低,单纯以“算法复现”和“代码实现”为核心的教学模式已难以有效支撑课程培养目标的达成^{[6][7]}。在此情形下,如何引导学生合理利用生成式工具,将学习重心从被动的技能训练转向主动的问题分析与解决能力培养,成为《机器学习》课程教学改革亟需回应的关键问题。混合式教学通过线上资源与线下教学活动的有机融合,为重构课程教学结构、强化学习过程管理与能力导向评价提供了现实路径。

基于此,本文以深圳大学电子与信息工程学院《机器学习》课程为研究对象,探讨在生成式编程工具普及的背景下,如何通过混合式教学改革重构课程教学环节,在保证学生算法理解与实现能力的基础上,进一步强化真实问题驱动的学习情境,引导学生围绕数据理解、模型设计、性能评估与方案优化开展系统性探究,从而实现课程教学目标由“技能训练”向“问题解决能力培养”的转型升级。

2 生成式编程工具的教学背景与启示

2.1 生成式编程工具的特征与优势

生成式编程工具是指基于大语言模型的智能代码生成与优化系统,具有强大的自然语言理解与程序生成能力。典型代表如 GitHub Copilot、ChatGPT Code Interpreter 等,可根据自然语言描述自动生成代码片段、解释算法原理、优化运行效率并提供调试建议。与传统 IDE 编程环境相比,这类工具不仅具备“代码

辅助生成”的功能,更重要的是具备“语义理解”与“任务解释”能力,为学生提供即时反馈与高效学习路径。

在机器学习课程中,这类工具可用于:

- 自动生成常见算法(如 KNN、SVM、决策树、神经网络等)的实现代码,帮助学生聚焦模型原理与参数分析;
- 在实验中快速验证算法性能,节省重复性编码时间;
- 在项目实践中辅助学生进行数据清洗、特征提取与模型调优;
- 通过自然语言交互强化学生对算法逻辑的理解与表达能力。

2.2 教育应用的潜在挑战

然而,生成式编程工具的普及也带来了教学新挑战。学生可能依赖模型直接生成代码,从而忽视问题分析与方法设计过程,导致“工具熟练但思维薄弱”的学习结果。特别是在课程考核与项目设计环节,学生若缺乏独立思考与分析能力,极易产生学习惰性与知识碎片化问题。因此,在教学改革中,如何有效引导学生“善用工具而非依赖工具”,成为课程体系重构的关键问题。

3 混合式教学内容的教学设计

3.1 教材与知识体系更新

课程采用 Kevin P. Murphy 于 2022 年出版的英文教材《Probabilistic Machine Learning: An Introduction》,通过中英双语教学方式,引入图神经网络、推荐系统、小样本学习等前沿内容。此举旨在帮助学生理解大模型时代的机器学习结构,培养其国际化视野与学术表达能力。

3.2 教师—助教—学生三方协作机制

课程教学机制采用“三方协作”结构:

- 教师负责知识体系讲授与理论深化;
- 助教负责代码实现、实验指导与实践答疑;
- 学生通过翻转课堂参与主题表达与成果汇报。

该机制在课堂时间中保留固定理论讲授环节,同时设置灵活的项目实践与展示时间,形成“讲授—实践—表达”循环,促进学生主动探索与系统表达。

3.3 项目制探索型学习模式

课程设置自主探索型项目制学习,学生两人一组

围绕现实问题自选主题，如图像情感识别、个性化推荐或语音情绪分析等。项目要求学生完成问题建模—数据采集—方法设计—结果展示四个阶段。教师与助教全程指导，鼓励学生查阅顶会论文，自行实现模型并进行性能分析。项目成果以“团队展示+个人答辩”的形式进行评估，考察其逻辑思维与学术表达能力。

3.4 多维度综合评价体系

评价体系采用“全过程、多主体、多维度”的结构，涵盖以下四个维度：

- (1) 理论理解与课堂参与度；
- (2) 编程实践与工具使用能力；
- (3) 问题建模与创新思维；
- (4) 表达能力与协作水平。

综合成绩由教师评分、同伴互评与听众反馈共同构成，强化学生的责任意识与自我反思能力。

4 基于生成式编程的混合式教学实践案例：以 MNIST 手写字识别项目为例

为验证前三章所提出的混合式教学改革理念在实际教学中的可操作性与有效性，本文选取 MNIST 手写数字识别任务作为综合实践案例，对“生成式编程工具支持下的问题驱动型学习过程”进行具体展开。该案例并非以追求模型精度为目标，而是围绕机器学习问题求解的完整流程，重点考察学生在问题建模、模型选择、参数分析与结果解释等关键环节中的学习行为变化，从而检验课程由“技能训练”向“问题解决能力培养”转型的实际效果。

4.1 案例选取与教学设计目标

MNIST 手写数字识别是机器学习课程中经典的入门级任务，具有数据规模适中、问题定义清晰、模型选择空间丰富等特点，适合作为教学改革中的引导性综合案例。在本课程中选取该任务，并非为了训练学生实现某一特定模型，而是旨在通过一个低门槛但结构完整的问题，引导学生系统经历“问题抽象—模型构建—参数分析—结果评价”的完整机器学习问题求解过程。

结合第三章提出的混合式教学设计，本案例被定位为课程前期的示范性项目：在生成式编程工具辅助下，降低代码实现负担，将学生的学习重心从“如何写代码”转移到“为什么选择该模型”“参数变化为何影响性能”“不同方法适用于何种问题情境”等高阶认知活动上，为后续更复杂的开放性项目奠定方法论基础。

4.2 问题建模与多模型对比：引导学生理解模

型假设差异

在项目实施初期，教师首先引导学生从问题建模角度分析手写数字识别任务，将其抽象为一个典型的分类监督学习问题，明确输入特征空间、输出类别集合及评价指标。在此基础上，并未直接指定最优模型，而是要求学生结合课程内容，自主选择并对比多种具有代表性的模型结构。



图 1 MNIST 手写数字识别项目实现流程

在生成式编程工具的辅助下，学生分别构建了 PCA+Logistic Regression、PCA+k-NN 以及 PCA+SVM 等模型组合。工具主要用于提供基础代码框架与接口示例，而模型选择理由、特征处理方式及实验对比方案均需由学生自行说明。通过该过程，学生逐步认识

到不同模型在特征表达能力、计算复杂度与泛化性能方面的本质差异，而非简单关注单一准确率指标。整体生成式编程工具使用实现流程如图 1 所示。

部分核心代码如下：

```
def evaluate_model(name, model, X_train, X_test,
                  y_train, y_test):
    print(f">>> {name} 训练中...")
    start = time.time()
    model.fit(X_train, y_train)
    acc = accuracy_score(y_test,
                        model.predict(X_test))
    print(f"准确率: {acc:.4f} | 用时: {time.time() - start:.2f} 秒\n")
    return acc

# 使用
evaluate_model("Logistic Regression",
              LogisticRegression(max_iter=1000, n_jobs=-1),
              X_train_pca, X_test_pca,
              y_train, y_test)

evaluate_model("k-NN",
              KNeighborsClassifier(n_neighbors=5,
                                weights='distance', n_jobs=-1),
              X_train_pca, X_test_pca,
              y_train, y_test)

evaluate_model("SVM (RBF)",
              SVC(kernel='rbf', C=10, gamma=0.01),
              X_train_pca, X_test_pca,
              y_train, y_test)
```

```
[1/6] 正在加载 MNIST 数据集...
数据加载完成, 总样本数: 70000
[2/6] 正在划分训练集与测试集...
训练集大小: (60000, 784)
测试集大小: (10000, 784)
[3/6] 正在进行数据标准化...
标准化完成
[4/6] 正在进行 PCA 降维 (保留 95% 信息) ...
PCA 降维完成, 特征维度: 332
[5/6] 正在训练并评估多种模型...

>>> PCA Logistic Regression 训练中...
准确率: 0.9225 | 用时: 25.71 秒

>>> PCA k-NN 训练中...
准确率: 0.9516 | 用时: 1.66 秒

>>> PCA SVM (RBF 核) 训练中...
准确率: 0.8932 | 用时: 1231.80 秒
```

图 2 初步实验结果

4.3 参数敏感性分析：从结果观察到机制解释

在完成基础模型搭建后，学生通常已取得一定的初步实验结果（如图 2 所示）。教学重点进一步转向模型参数对性能影响的系统分析。教师引导学生围绕降维维数、分类器超参数等关键因素，设计对照实验并进行定量比较。例如，在 PCA+SVM 模型中，学生需要分析核函数参数与正则化系数变化对识别精度与训练时间的综合影响。



ChatGpt

你的SVM为什么准确率反而比k-NN低 + 时间又超长?

最主要的原因大概率是：
gamma=0.01 偏小 + C=10 偏大 → 模型倾向于记住比较多的支持向量 → 训练极慢 + 容易轻度过拟合或欠拟合边界区域

强烈推荐先试这几个组合 (通常最稳)

C	gamma	预期准确率	训练时间预期
10	0.001	~94~95%	还很慢
1	0.001	~93~94.5%	明显变快
5~10	0.0005	~94~96%	中等偏慢
1~5	0.0001	~93~95%	比较快 (推荐入门)

最推荐入门组合 (平衡速度与效果) :

SVC(kernel='rbf', C=5, gamma=0.0005) # 或 0.001

图 3 MNIST 手写数字识别项目参数修改问答

当实验结果出现“模型精度未随复杂度提升而提高”等反直觉现象时，鼓励学生通过如图 3 所示的生成式编程工具进行针对性提问，以获得参数作用机制的解释，而非直接修改代码以追求最优结果（如图 4 所示）。通过“结果—提问—解释—再实验”的循环过程，学生逐步建立起对模型假设与参数机制的理解，体现了从经验性调参向理性分析的转变。

```
MNIST 手写数字识别 (多模型对比实验)

[1/6] 正在加载 MNIST 数据集...
数据加载完成, 总样本数: 70000
[2/6] 正在划分训练集与测试集...
训练集大小: (60000, 784)
测试集大小: (10000, 784)
[3/6] 正在进行数据标准化...
标准化完成
[4/6] 正在进行 PCA 降维 (保留 95% 信息) ...
PCA 降维完成, 特征维度: 332
[5/6] 正在训练并评估多种模型...

>>> PCA Logistic Regression 训练中...
准确率: 0.9225 | 用时: 18.90 秒

>>> PCA k-NN 训练中...
准确率: 0.9516 | 用时: 1.00 秒

>>> PCA SVM (RBF 核) 训练中...
准确率: 0.9694 | 用时: 96.02 秒
```

图 4 修改后实验结果

4.4 教学成效分析

以上教学方法与 2024-2025 学年在深圳大学“电子信息拔尖创新实验班”（深圳大学四个院士班之一—文华班）的《机器学习》双语课程进行实施。在线性回归、朴素贝叶斯分类器、前馈神经网络算法、决策

树等四个实验,以及以“葡萄酒品质分类”未代表的课程项目中,引导学生重点对比各种机器学习模型在性能、训练速度、收敛性等全面的分析与理解,与课本知识相结合分析性能提升的主要技术因素,并指导学生基于生成式编程工具对核心理论算法进行编程实现。在课题研究过程中学生展示出了很强的主动探索意识,与教师和助教频繁就机器学习技术和编程实践问题进行咨询讨论。每个小组通过约 6 周的专题研究,最终通过分组课堂汇报的形式汇报对机器学习模型探索经验、数值分析结果、以及针对当前行业发展的适当延展。

如图 5 所示,借助生成式编程工具的支持,学生能够在统一实验平台与评价指标下高效并行地比较不同模型及其参数配置对识别性能的影响,将学习重心由底层代码实现细节转向模型假设、特征表示能力、参数影响机制及性能差异分析等高阶认知活动。通过模型对比实验与参数分析实验的综合训练,学生能够更加系统地理解机器学习方法体系,并在实验报告与课堂展示中对不同模型及参数设置的适用场景与优劣势进行深入分析,而非仅关注单一性能指标的高低。82.76%的同学表示在基于生成式工具编程的探究中找到了学习的乐趣,有成就感。以上结果基本验证所实践的方法能够帮助学生加深对理论知识点的理解,在混合式教学中增强对工程技术问题的分析和解决能力,并且提升对技术研究工作的热情。

4.5 小结:案例对混合式教学改革目标的支撑作用

通过 MNIST 手写数字识别案例的实施,可以看出生成式编程工具在混合式教学框架下并未削弱学生的学习深度,反而在合理引导下有效促进了其问题解决能力的形成。学生能够在较短时间内完成多模型对比与参数分析,将主要精力投入到问题建模、方法选择依据及实验结果解释等关键认知活动中。

该案例验证了前三章提出的教学改革思路具有良好的可实施性:在混合式教学环境中,通过项目制任务与生成式工具的协同使用,可以有效推动《机器学习》课程从“算法实现导向”向“问题求解导向”转型,为后续开放性课程项目与科研训练提供了方法论支撑。

5 结束语

本研究在生成式编程工具普及的背景下,探索了《机器学习》课程的混合式教学改革路径。通过教材体系更新、协作式教学机制、项目制探索学习与多维评价体系的系统设计,课程实现了从“技能训练”向“问题解决能力培养”的转型。教学实践表明,该模式不仅提升了学生的思维逻辑与科研表达能力,也为高校

人工智能类课程的教学改革提供了可推广的范例。



ChatGpt

max_iter 是逻辑回归优化过程中允许的最大迭代次数,用来控制模型何时停止训练。

简单来说:
max_iter 越大 → 给优化算法更多机会去寻找更好的参数解,模型更容易收敛到更低的损失(训练集表现更好),但训练时间会显著增加

max_iter 越小 → 训练很快停止,即使还没完全收敛也强制结束,模型可能欠拟合(训练集准确率偏低),但计算成本很低

一句话总结: max_iter 越大越「执着」、越追求极致拟合; max_iter 越小越「急性子」、越注重训练速度。

n_jobs=-1 表示在进行多分类任务时(默认使用 one-vs-rest 策略),允许同时使用计算机上所有可用 CPU 核心来并行训练多个二分类器。

简单来说:
n_jobs=-1 → 充分利用多核 CPU,大幅缩短训练时间(对 10 类的 MNIST 这种多分类问题加速非常明显)

n_jobs=1 (默认) → 只用单核,训练明显变慢,但占用资源少

一句话总结: n_jobs=-1 就是告诉模型“别客气,把我所有 CPU 火力都拉满”

解释KNN中n_neighbors和weights这两个参数



ChatGpt

n_neighbors 是 k-NN 在预测时要参考的最近邻居数量,决定了“民主投票”的参与人数。

简单来说:
n_neighbors 越小(比如 1 或 3) → 只听少数附近样本的意见,决策边界非常精细、锯齿状,对噪声非常敏感,容易过拟合

n_neighbors 越大(比如 15 或 50) → 听很多邻居的意见,决策边界变得越来越平滑、简单,对噪声鲁棒,但可能丢失局部细节,容易欠拟合

一句话总结: n_neighbors 越小越「挑剔」、越相信身边少数人; n_neighbors 越大越「随和」、越听大多数人的声音。

weights='distance' 决定了邻居投票时的权重分配方式。

简单来说:
weights='distance' → 距离越近的邻居说话越算数(权重 = 1/距离),更重视局部信息,通常在实际数据中效果更好

weights='uniform' (默认) → 所有邻居一票平等,不管远近

一句话总结: weights='distance' 就是“离我近的人说话更有分量”,让模型更聪明地权衡邻居的重要性。

解释SVM中C和gamma这两个参数



ChatGpt

C 参数(正则化惩罚系数), C 是 SVM 中用来平衡「分类错误」和「决策边界简单性」之间的权衡参数。

简单来说:
C 越大 → 越不允许分类错误(对训练集的每个错分点惩罚很重),模型会尽量把所有训练样本都正确分类 → 决策边界更复杂、更弯曲,容易过拟合

C 越小 → 更允许有一些样本被错分,模型会倾向于选择更简单、更平滑的边界 → 泛化能力通常更好,但训练集准确率可能下降

一句话总结: C 越大越「硬核」、越追求训练集完美; C 越小越「宽容」、越注重泛化。

gamma 参数(RBF 核函数的宽度参数), gamma 控制了每一个训练样本的影响范围(相当于高斯函数的宽度)。

简单来说:
gamma 越大 → 单个样本的影响范围很小 → 决策边界会变得非常精细、局部、弯弯曲曲(像很多小山丘),容易过拟合

gamma 越小 → 每个样本的影响范围很大 → 决策边界变得非常平滑、整体、大范围(像大波浪),模型更简单,容易欠拟合

一句话总结: gamma 越大,模型越「近视」、越关注局部细节; gamma 越小,模型越「远视」、看全局趋势。

图 5 参数解释说明

未来,课程团队将进一步完善基于大模型的教学辅助系统,建设在线知识库与智能反馈平台,实现教学过程的数据化与个性化指导,持续推动理工科课程教学模式的智能化转型。

参 考 文 献

- [1] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- [2] Bishop C M. Pattern Recognition and Machine Learning[M]. New York: Springer, 2006.
- [3] 陈伟, 贺丽娜, 丁娟. 混合式教学“金课”模式在“数据结构与算法”课程中的实践与探索[J]. 南方农机, 2025, 56(24): 172-174, 184.
- [4] 秦婧. 机器学习课程中分类模型综合实验的教学设计[J]. 通讯世界, 2025, 32(11): 63-65.
- [5] 公维军, 李莉, 彭志超. 数智化视域下的“机器学习”课程改革探索与实践[J/OL]. 工业和信息化教育, 2026, 01(13), 1-5.
- [6] 张喜英, 任志考, 叶臣, 等. AI赋能编程类课程教学的创新研究与应用[J/OL]. 江苏建筑职业技术学院学报, 2026, 01(13), 1-8.
- [7] 方维, 袁宝库, 梁峰绮. 基于PTA平台的程序设计类课程教学改革实践[J]. 计算机技术与教育学报, 2022, 10(1): 97-100.
- [8] 傅继彬. 构建计算机网络课程中的思政教育协议栈[J]. 计算机技术与教育学报, 2022, 10(05), 23-26.