科学通报 2026 年 第 71 卷 第 15 期: 3440 ~ 3450
自然科学基金项目进展专栏 进 展
《中国科学》杂志社
SCIENCE CHINA PRESS

高能物理中的量子可行性验证与优势探索: 喷注重建与事例分类的前沿算法

朱永峰[1†], 吴金哲[2†], 周辰[3*]

1. 中国科学院高能物理研究所, 北京 100049
2. 吉林大学物理学院, 长春 130012
3. 北京大学物理学院, 核物理与核技术全国重点实验室, 北京 100871
† 同等贡献
* 联系人, E-mail: czhouphy@pku.edu.cn

2025-12-24 收稿, 2026-02-06 修回, 2026-02-10 接受, 2026-02-11 网络版发表
国家自然科学基金(12522507)资助

摘要 随着高能物理实验全面迈入“大数据时代”, 事件规模和分析复杂度迅速提升, 经典计算方法在处理高维特征、组合优化和海量数据时逐渐显现出性能瓶颈. 量子计算依托量子叠加与纠缠所带来的潜在并行性, 为应对这些挑战提供了新的技术路径. 本文介绍了量子计算在高能物理分析中的两项代表性工作: 其一是基于量子近似优化算法实现喷注聚类, 将该任务映射为最大割问题并展示了量子–经典混合优化在事件重建中的可行性; 其二是基于量子核支持向量机用于环形正负电子对撞机的希格斯事例分类, 通过量子特征映射实现与经典核支持向量机相当的信号–本底区分性能. 尽管当前量子硬件仍受限于噪声、量子比特数和退相干等因素, 但已有一系列前沿研究在小规模喷注重建和事例分类等任务中验证了量子算法的可行性并开展了量子优势的初步探索. 随着硬件保真度提升、量子误差缓解与可扩展分治策略的发展, 量子计算有望在未来高能物理实验的数据处理与分析中发挥越来越重要的作用.

关键词 量子计算, 量子优化, 量子机器学习, 高能物理, 喷注重建, 事例分类

高能物理研究的核心目标在于探索物质的基本组成和宇宙最根本的相互作用规律. 通过研究高能量尺度下粒子的产生、传播与湮灭过程, 人类得以不断加深对物质结构与自然法则的理解. 近年来, 随着实验规模的迅速扩大和探测器性能的持续提升, 高能物理实验的数据采集与处理需求呈现出指数级增长趋势. 目前, 大型对撞机实验, 如欧洲核子研究组织(European Organization for Nuclear Research, CERN)的大型强子对撞机(Large Hadron Collider, LHC), 每年产生的数据量已达到数十PB, 即便配备多级在线触发系统用于实时筛选事件, 仍需长期存储与处理海量数据[1]. 预研中的全球多个大型粒子对撞机, 如环形正负电子对撞机(Circular Electron-Positron Collider, CEPC)、未来环形正负电子对撞机(Future Circular Electron-Positron Collider, FCC-ee)、国际直线对撞机(International Linear Collider, ILC)等, 产生的数据规模和对精确测量的需求都将远超现有水平[2~4].

尽管经典计算方法已在高能物理任务中取得显著进展, 例如: 粒子重建算法(如Particle Flow)[5]、基于树状结构的喷注重建算法[6]、信号-本底分类中用到的提升决策树方法[7], 但在当前和未来实验需求面前仍面临多重瓶颈. 首先, 喷注重建等关键任务本质上属于组合

引用格式: 朱永峰, 吴金哲, 周辰. 高能物理中的量子可行性验证与优势探索: 喷注重建与事例分类的前沿算法. 科学通报, 2026, 71: 3440–3450
Zhu Y, Wu J, Zhou C. Quantum feasibility verification and advantage exploration in high-energy physics: frontier algorithms for jet reconstruction and event classification (in Chinese). Chin Sci Bull, 2026, 71: 3440–3450, doi: 10.1360/CSB-2025-5947

© 2026《中国科学》杂志社

优化问题，在大规模事件中呈现接近NP-hard的复杂度[6,8]，导致计算成本随粒子数指数级增加. 其次，与QCD强子化过程相关的高精度模拟需要大量计算资源，使得全链路事件生成与探测器模拟难以满足统计要求[8~10]. 此外，高维特征空间带来的“维度灾难”显著增加分类器与重建算法的训练样本需求、内存消耗与推理时间, 而模型性能的提升却逐渐趋于饱和[6,11].

在此背景下, 量子计算作为一项新兴技术, 正逐步从理论研究迈向实验可行性验证阶段，为高能物理中的高维数据分析、复杂组合优化和概率模拟提供新的可能性. 量子计算在求解某些特定类型的优化问题、核方法以及非线性映射方面表现出潜在的指数级优势, 使其成为应对未来高能物理计算挑战的重要候选技术[12,13].

本文旨在系统回顾和分析近年来量子计算在高能物理中的代表性应用，重点关注两类典型量子算法框架: (1) 基于量子近似优化算法(quantum approximate optimization algorithm, QAOA)的喷注聚类方法，属于事件重建阶段中的组合优化问题; (2) 基于量子核支持向量机(quantum support vector machine with kernel, QSVM-Kernel)的Higgs事例分类方法, 对应下游物理分析中的机器学习分类问题. 通过这些内容, 我们希望为高能物理在后摩尔时代的计算升级提供参考与启示.

1 量子计算在高能物理分析中的应用

随着高能物理实验进入数据量与分析复杂度同步爆发的阶段，经典计算体系在存储、计算与算法层面均面临愈发严峻的挑战. 量子计算依托量子叠加与纠缠所构成的高维希尔伯特空间，在某些特定问题上有望提供超越经典的计算能力. 例如, Shor算法在整数因数分解问题上实现指数级加速, Grover算法在无结构搜索中提供平方级加速[14,15]. 尽管当前量子硬件仍处于噪声中等规模(noisy intermediate-scale quantum, NISQ)阶段, 可用量子比特数有限且门操作存在非可忽略误差[16], 但理论与实验的持续进展表明: 量子计算有望在未来十年内对部分高能物理任务产生实质性影响[13].

在NISQ条件下, 量子-经典混合算法成为连接现有硬件能力与量子可行性验证或优势探索的主要途径. 与本文密切相关的技术路线可大致分为两条: 一条是以变分量子算法(variational quantum algorithms, VQAs)为代表的参数化量子线路方法，另一条是以量子核方法(quantum kernel methods)为代表的量子增强核学习方案[12,17~19]. 前者通过在量子处理器上执行带可调参数的量子线路并由经典优化器迭代更新参数, 实现对目标函数的近似最优化; 后者则利用量子特征映射将经典数据嵌入高维量子态空间，并在量子设备上显式评估核函数，经典核方法提供量子增强的特征表达能力.

变分量子算法是当前NISQ时代研究最活跃的量子算法家族之一[18]. 其基本思路是在给定问题哈密顿量或目标函数的基础上，构建含可调参数的量子线路作为ansatz，通过在量子处理器上评估代价函数，结合经典优化器对参数进行迭代更新，从而在有限线路深度下逼近最优解. 典型代表包括用于求解量子多体体系基态能量的变分量子本征求解器(variational quantum eigensolver, VQE), 以及面向经典组合优化问题的量子近似优化算法等[18,20,21]. 在高能物理分析中, 喷注重建、顶夸克重建等关键步骤本质上可归结为图划分、指派或匹配等组合优化问题，其计算复杂度随末态粒子数目呈指数级增长[6,8]. 将此类任务映射为恰当的优化问题后，可借助QAOA等VQA框架在量子叠加态中并行探索解空间，有望在搜索效率和解的质量之间取得新的平衡.

与以VQA为代表的参数化量子线路路线并行，量子核方法为量子计算赋能高能物理提供了另一条重要途径[12,17]. 高能物理实验数据通常呈现高维、强相关和高度非线性的特征，使得传统分类器在有限样本和有限模型容量下难以充分区分信号与本底. 量子核方法通过预设的量子特征映射将事例级特征嵌入高维量子态空间，并在量子设备上评估不同事件对的核函数[22]. 在获得量子核矩阵后, 训练过程由经典核方法完成, 由此在量子构建的特征空间中实现监督学习. 基于量子核方法构建的量子支持向量机是当前量子机器学习在高能物理应用中的主要代表之一. 借助量子特征映射提供的高维嵌入与量子干涉特性，QSVM-Kernel能够在不增加训练样本规模的情况下有效提升决策边界的表达能力，尤其适用于事例级信号-本底分类等模式识别任务.

为了展示这些量子算法在实际高能物理流程中的可行性与潜力，下文将结合两个具有代表性的任务具体展开: 基于QAOA的喷注聚类作为量子优化在事件重建中的典型应用[23]，以及基于QSVM-Kernel的Higgs事例分类作为量子机器学习在数据分析中的典型案

例[24]. 这两个方向分别对应高能物理分析链的关键步骤, 展示了量子计算如何在NISQ时代以可验证的方式嵌入目前的物理分析框架, 并为未来可能的量子加速奠定基础.

2 代表性工作一——QAOA应用于喷注聚类

在高能粒子对撞实验中, 夸克[25]和胶子产生后会迅速形成方向高度一致的粒子簇射, 称为喷注. 精确的喷注重建不仅能够保留初始夸克或胶子的信息, 也是研究希格斯玻色子[26~28]性质的重要基础, 而希格斯机制正是解释亚原子粒子质量起源的关键. 周辰研究团队首次得到了QAOA应用于喷注重建问题上的实验结果[23]. 该团队将对撞事例映射为图结构(节点表示粒子, 边的权重表示粒子间夹角, 对于每个节点, 其相连的边按权重从大到小排序, 并仅保留前k条边, 据此构造由参数k控制的稀疏化无向图), QAOA可以以类似于求解Max-Cut[29]问题的方式进行喷注重建. Max-Cut问题定义如下: 对于一个无向图$G=(V,E)$, 其中V为顶点集合, E为边集合, 且$w_{ij}>0$表示连接顶点i和j的边$(i,j)\in E$的权重, 将图的顶点划分为两个互补子集, 使得连接两个子集顶点的边的权重之和最大化, 其表达式为: $C(x)=\sum_{i,j=1}^{|v|}w_{ij}x_i(1-x_j)$. 求解$C(x)$的最大值是一个NP-hard问题, 而QAOA可以使$C(x)$尽可能接近最大值$C_{\max}=\max_x C(x)$[21].

2.1 量子近似优化算法

QAOA的设计灵感来源于量子绝热算法(quantum adiabatic algorithm, QAA)[30]. 下文给出QAOA用于求解Max-Cut问题的简要介绍. 对于图$G=(V,E)$的最大分割问题, 定义成本哈密顿量:

$$\widehat{H_C}=\frac{1}{2}\sum_{(i,j)\in E}w_{ij}(I-Z_iZ_j) \tag{1}$$

和混合哈密顿量

$$\widehat{H_M}=\sum_{j\in V}X_j, \tag{2}$$

其中, I为单位算符, $Z_i(X_j)$为作用于第$i(j)$个量子比特的Pauli-Z(Pauli-X)算符. 将量子线路初始化到态$|s\rangle$: $|s\rangle=|+\rangle^{\otimes N}=\frac{1}{\sqrt{2^N}}\sum_{x\in(0,1)^N}|x\rangle$, 其中量子比特数$N=|V|$. 通过作用以下幺正算符构建线路ansatz:

$$\widehat{U_C}(\gamma)=\mathrm{e}^{-\mathrm{i}\gamma\widehat{H_C}}=\prod_{i=1,j<i}^{N}R_{Z_iZ_j}(-2w_{ij}\gamma), \tag{3}$$

$$\widehat{U_M}(\beta)=\mathrm{e}^{-\mathrm{i}\beta\widehat{H_M}}=\prod_{i=1}^{N}R_{X_i}(2\beta), \tag{4}$$

其中, γ和β是线路的变分参数. 初始化$2P$个变分参数(P为QAOA的深度): $\gamma=(\gamma_1,\gamma_2,\ldots,\gamma_P)$和$\beta=(\beta_1,\beta_2,\ldots,\beta_P)$, 其中$\gamma_k\in[0,2\pi),\beta_k\in[0,\pi)$, $k=1, 2, ..., P$. 线路最终输出态为

$$|\psi_P(\gamma,\beta)\rangle=\mathrm{e}^{-\mathrm{i}\beta_P\widehat{H_M}}\mathrm{e}^{-\mathrm{i}\gamma_P\widehat{H_C}}\ldots\mathrm{e}^{-\mathrm{i}\beta_1\widehat{H_M}}\mathrm{e}^{-\mathrm{i}\gamma_1\widehat{H_C}}|s\rangle. \tag{5}$$

对末态$|\psi_P(\gamma,\beta)\rangle$在计算基下进行重复测量(该分析中测量1024次), 以计算哈密顿量$\widehat{H_C}$的期望值:

$$F_P(\gamma,\beta)=\langle\psi_P(\gamma,\beta)\,|\,\widehat{H_C}\,|\,\psi_P(\gamma,\beta)\rangle. \tag{6}$$

使用经典优化算法(该分析中采用COBYLA[31])迭代更新参数γ和β. 目标是找到使期望值最大化的最优参数集合(γ^*,β^*). 末态$|\psi_P(\gamma^*,\beta^*)\rangle$编码了优化问题的解.

2.2 喷注重建性能

喷注重建性能的评价标准是重建喷注与其对应夸克之间的夹角. 在过程$e^+e^-\to ZH(Z\to\nu\bar{\nu},H\to s\bar{s})$中, 每个对撞事件会产生两个喷注, 因此对应两个夹角, 记为$angle_1$和$angle_2$. 研究团队采用夹角之和$angle_1+angle_2$作为喷注重建性能的评价指标. 为了保证统计可靠性, 研究团队分析了4000个对撞事件, 每个事件包含30个粒子.

QAOA的性能与QAOA的深度有关. 增加QAOA深度意味着量子演化算符$\widehat{U}(t)$的Trotter化步长更细, 从而允许更精细的演化增量. 这种增量的细化有助于量子系统在从初始哈密顿量演化到问题哈密顿量的过程中, 保持系统状态处于基态. 图1(a)比较了在深度为1、3和5且k值固定为6时的喷注重建效果. 正如图1(a)所示, 深度为3和5的结果相当, 并明显优于深度为1的结果, 验证了基态采样的成功.

在该分析中, 较大的k值意味着图中每个节点与更多节点相连, 从而对应更复杂的量子线路. 特别地, 较大的值可能导致一个粒子与同一喷注内的其他粒子相

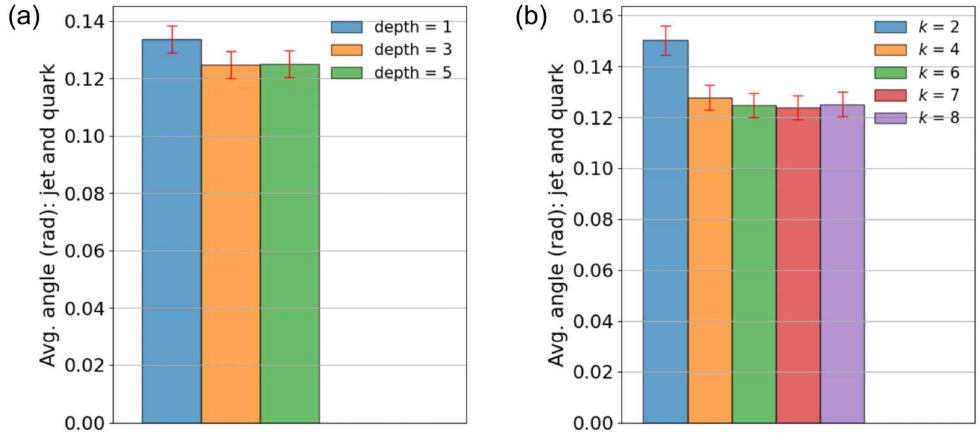


图 1 4000个末态含30粒子的对撞事件的喷注重建性能(QAOA方法)[23]. (a) 当k值为6, QAOA深度分别为1、3和5时的喷注重建性能. (b) QAOA深度固定为3时, 不同k值(2、4、6、7、8)下的喷注重建性能

Figure 1 Jet clustering performance of the QAOA method for 4000 events with 30 particles[23]. (a) The performance of k (k-nearest-neighbor sparsification) set to 6 and QAOA depths of 1, 3, and 5. (b) The performance of QAOA depth set to 3 and k values of 2, 4, 6, 7, and 8

连, 增加了同一喷注内粒子被分到两个不同喷注的可能性. 相反, 较小的k值可能导致来自不同喷注的粒子之间连接不足, 从而无法准确将它们划分到不同的喷注中, 导致喷注重建性能下降. 图1(b)展示了在QAOA深度固定为3时, k值分别为2、4、6、7和8的喷注重建性能对比. 结果表明, k = 7时的喷注重建性能最佳.

为了更直观地比较QAOA对喷注重建性能的影响, 图2(a)展示了QAOA(在深度为3且k值为7时)与两种经典算法k-Means[32]和$e^+e^-k_t$[33]的喷注重建性能对比. k-Means是一种无监督机器学习方法, 通过将每个数据点分配给距离其质心最近的簇, 将数据集划分为k个互不重叠的簇. 在该研究的喷注重建中, k-Means使用两个粒子之间的夹角作为距离度量. 是用于电子-正电子碰撞中的经典喷注重建算法, 其基于粒子间的角度和粒子的能量计算粒子间的距离: $d_{ij}=2\min\left(E_i^2,E_j^2\right)\left(1-\cos\theta_{ij}\right)$, 其中$E_{i/j}$表示粒子$i/j$的能量, θ_{ij}表示粒子i和j之间的夹角. 该算法通过识别最近的粒子对并将其合并, 然后重复这一过程, 直至满足某个停止条件. 结果显示, QAOA的喷注重建性能可与$e^+e^-k_t$算法相媲美, 并优于k-Means算法. 这一比较凸显了QAOA在喷注重建问题中的潜力.

此外, 研究团队在BAQISQuafu量子计算云平台(https://quafu.baqis.ac.cn)进行了分析. 由于当前硬件存在噪声和连接性(每个量子比特只能与其相邻的2或3个量子比特交互, 导致编译后的量子线路深度增加)等限制, 该研究将分析对象限制为6个量子比特, 即包含6个末态粒子的对撞事件. 研究发现, 当QAOA深度设置为1且k = 2时, 喷注重建性能已接近最优. 作为演示, 图2(b)展示了在Baihua处理器上完成的1217个6粒子事件的实验结果. 结果表明, 对于这一小规模问题, 量子硬件的性能可与无噪声量子计算机模拟器相媲美.

2.3 总结与拓展

从工作一对不同线路深度与图结构设置的比较可以看到, 在给定距离度量与停止准则后, 喷注聚类可视为一类带约束的组合优化问题. 经典分析中常用的k_t、Cambridge/Aachen与$anti-k_t$等序列重组算法, 已在FastJet等工具中形成标准化实现方案[6,33]; 然而当事件粒子数无效字符()请检查修改 无效字符()请检查修改增长或需在特定物理目标下引入额外约束时, 搜索空间与组合路径会显著膨胀, 从而加剧计算资源压力并影响可获得的统计量[8,9]. QAOA为此提供了将离散优化映射到可参数化量子线路的统一途径: 通过问题哈密顿量与混合哈密顿量的交替演化, 在有限深度下近似原本难以求解的全局最优解, 从而为喷注重建环节引入可控的量子增强搜索能力[18,19,21].

该研究目前仅在的模拟与N = 6的真机上验证[23]; 当外推至LHC或高亮度LHC的高堆积(pile-up)运行条件所对应的多粒子事件环境时(单事件可重建末态粒

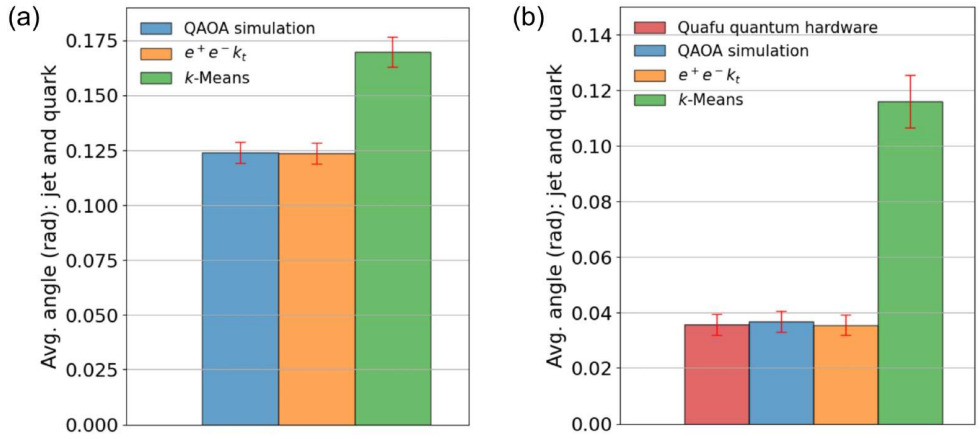


图 2 (a) 对含30个末态粒子对撞事件的喷注重建性能的比较, 比较对象包括QAOA方法(QAOA深度为3, k值为7)、$e^+e^-k_t$算法及k-Means算法. (b) 在Quafu平台上对1217个含有6个末态粒子的对撞事件进行喷注重建的性能比较, 比较对象包括量子模拟器、$e^+e^-k_t$算法和k-Means算法, 其中QAOA深度设置为1, k值设置为2[23]

Figure 2 (a) The jet clustering performance for events with 30 particles, comparing the QAOA method (with QAOA depth of 3 and k of 7), $e^+e^-k_t$ algorithm, and the k-Means method. (b) The jet clustering performance for 1217 6-particle events on the Quafu platform, comparing the quantum simulator, $e^+e^-k_t$ algorithm, and the k-Means method, with QAOA depth set to 1 and k set to 2[23]

子数可达数百乃至更高), 在以粒子为节点的编码下量子比特数随N线性增长, 若保持由参数k控制的无向稀疏图构造, 则每层代价演化需要约$|E| = kN/2$个两比特相互作用, 其总规模随深度p近似呈$O(p|E|)$增长. 在受限耦合拓扑下, 线路编译时通常需要插入SWAP, 导致两比特门数与有效线路深度的增加[34,35]; 同时, 变分量子-经典优化在每次参数更新时都需通过有限次重复运行与测量以估计期望值, 且经典优化器需要多次评估才能满足停止准则, 随着单事件粒子规模的增大以及对估计精度要求的提高, 所需采样(shots)与电路调用次数可能显著增长, 从而使测量过程可能成为总体运行时间的重要瓶颈[18,19]. 因此, 直接按粒子数线性扩展将受限于可用比特数、门保真度与可执行深度, 一个可行的方案是结合经典预处理将量子优化限定于关键局部决策, 并在可控资源下评估其对重建质量的提高[8,36].

面向后续研究, QAOA在喷注重建中的拓展可聚焦于三点: 其一, 面向大规模事件的可扩展机制, 例如分治求解、子问题拼接与参数迁移/热启动等策略, 以降低线路深度与量子调用成本并提升跨事件复用效率[19,21]; 其二, 针对NISQ噪声的鲁棒化设计, 在控制线路深度的同时结合误差缓释与统计重采样, 使输出分布在不同硬件批次下保持可比性[18,19]; 其三, 从"算法解"走向"物理可用解", 把QAOA输出对喷注质量指标以及下游机器学习判别变量的影响纳入可复现的验证框架, 并在统计推断中一致处理可能引入的偏差与系统学漂移[7,9].

3 代表性工作二——QSVM-Kernel应用于Higgs事例分类

在未来的正负电子希格斯工厂中, 从庞大本底中精准挑出稀少的希格斯信号, 是实现精密测量的核心环节之一. 以CEPC的$e^+e^- \to ZH$过程为例, 尤其是$H \to \gamma\gamma, Z \to jj$等末态, 信号事例淹没在光子与喷注多体过程的大量本底之中, 高效而稳健的信号-本底分类器直接决定了对产生截面和衰变分支比测量的灵敏度, 从而影响对希格斯耦合常数及其潜在偏离标准模型预言的约束能力. 本文所介绍的第二个工作, 首次将QSVM–Kernel直接应用于未来希格斯工厂的具体物理分析[24]. 这一研究与前述基于QAOA的喷注聚类工作相互补充, 从"喷注结构重建"和"信号-本底分类"两个关键环节展示了量子计算融入高能物理数据处理链的多样化能力[2~4,17].

3.1 量子支持向量机核方法

QSVM-Kernel基于支持向量机(support vector machine, SVM), 引入量子特征映射与量子核估计, 将经典数据编码到高维量子态空间中, 并利用量子线路实现

复杂核函数的计算，从而完成信号–本底分类，可以看作是将经典支持向量机推广到量子特征空间的一种具体实现[22,37~39]. 在该工作的CEPC Higgs物理分析中, 每个事例用一个六维的运动学特征向量$\vec{x}$表示. QSVM-Kernel首先通过一个量子特征映射线路$U_{\Phi(\vec{x})}$将经典向量编码到N个量子比特的状态:

$$|\Phi(\vec{x})\rangle = U_{\Phi(\vec{x})}|0\rangle^{\otimes N}, \tag{7}$$

这里$n = 6$, 与输入特征数目相同. 量子特征映射线路由两层相同的子结构组成，每层包含对每个量子比特依次施加的H门、R_z门以及R_y门，并在相邻比特之间插入交替排列的CNOT纠缠门. 该工作系统尝试了不同的单比特旋转组合和线路深度，比较在固定事件数下得到的AUC(area under curve)表现, 由此找到最适合数据集的量子特征映射.

在量子特征映射确定之后，QSVM-Kernel下一步是利用量子线路估计核函数. 对于任意两个事件$\vec{x}_i$和$\vec{x}_j$, 其核函数被定义为对应量子态的内积模方:

$$k(\vec{x}_i,\vec{x}_j) = \left|\left\langle \Phi(\vec{x}_i) \mid \Phi(\vec{x}_j)\right\rangle\right|^2. \tag{8}$$

$k(\vec{x}_i,\vec{x}_j)$衡量的是两组输入在高维量子态空间中的距离. 将式(8)写成:

$$k(\vec{x}_i,\vec{x}_j) = \left|\langle 0|^{\otimes N} U^{\dagger}_{\Phi(\vec{x}_i)} U_{\Phi(\vec{x}_j)}|0\rangle^{\otimes N}\right|^2, \tag{9}$$

可以在量子处理器上构造含有$U_{\Phi(\vec{x}_j)}$与$U^{\dagger}_{\Phi(\vec{x}_i)}$的复合线路, 作用在$|0\rangle^{\otimes N}$初态上, 并经过多次测量, 得到全零比特串$|0\rangle^{\otimes N}$的频率即给出了核函数值的估计.

最后一步沿用经典SVM求解流程，在量子态空间中寻找一个最优分离超平面:

$$\sum_{i=1}^{t} \alpha_i y_i k(\vec{x}_i,\vec{x}) + b = 0, \tag{10}$$

其中, t为训练样本数, α_i和b通过求解凸优化问题得到. 该步骤完全在经典计算机上完成，而量子处理器只负责计算核矩阵的各个元素. 对任意新的测试事件$\vec{x}'$, 只需在量子设备上评估, 将结果代入式(10)即可得到分类结果及其“信号似然度”输出，从而构成适用于物理分析的连续判别变量.

3.2 事例分类性能

为了评估QSVM-Kernel，研究团队选择了CEPC上的过程, 并聚焦于$H \to \gamma\gamma, Z \to jj$的衰变道. 该道具有清晰的最终态拓扑: 两个高能光子与两个喷注, 其主要本底为$e^+e^- \to (Z/\gamma^*)\gamma\gamma$过程. 在量子模拟方面, 研究团队使用了IBM Qiskit框架中的Statevector Simulator以及本源量子QPanda框架中的Tensor Network Simulator, 在经典计算机上演化量子态并给出理想测量概率(不考虑硬件噪声)[40,41]. 为评估统计涨落，样本被多次随机重排，每一次重排都独立训练并测试一个QSVM-Kernel分类器; 在超参数调优过程中, 则采用标准的交叉验证策略[42,43]. 经典对比方法选用基于RBF核的SVM分类器，并借助scikit-learn库实现[44]. 最终的性能指标为多次重排AUC的平均值及其标准差.

图3(a)展示了在包含12000个事例的数据集上(其中信号与本底各6000个)，QSVM-Kernel与经典基于RBF核的SVM分类器的ROC曲线几乎重合，两者的AUC也在统计误差范围内一致. 这表明, 在所选六维运动学特征与量子特征映射下，量子核估计已经能够达到与经典核方法相当的判别能力. 为了评估该流程在NISQ硬件上的可执行性并量化噪声对核估计的影响, 该研究进一步将同一QSVM-Kernel工作流部署到真实量子处理器上进行验证.

研究团队在两台超导量子计算机上实现了QSVM-Kernel算法: 一台是IBM提供的7比特Nairobi处理器(使用其中6个比特)，另一台是本源量子提供的6比特Wuyuan处理器. 结果如图3(b)所示，在同一数据集上, 量子硬件与量子模拟器给出的ROC曲线总体一致. 为了更定量地理解噪声效应，研究团队还利用IBM提供的FakeNairobi噪声模型，在QASM模拟器中注入与真实设备标定结果一致的门误差与读出误差. 在不确定度范围内，IBM硬件与噪声模拟结果相当，而本源Wuyuan的表现与IBM相比也处于同一量级. 这一系列对比表明, 在当前噪声水平下, 小规模QSVM-Kernel已经能够在真实量子设备上稳定运行，并给出接近无噪声模拟器的信号-本底分离能力.

为了进一步研究训练样本规模对量子核分类性能的影响，研究团队还构建了从200个事例到12000个事例的多个数据集，对每个规模分别训练QSVM-Kernel和经典SVM分类器. 如图4(a)所示, 随着样本数的增加, 两种方法的AUC均单调提升，并在样本数量大于4000后逐渐趋于饱和.

同时, 图4(b)展示了两种方法的AUC差值随样本规

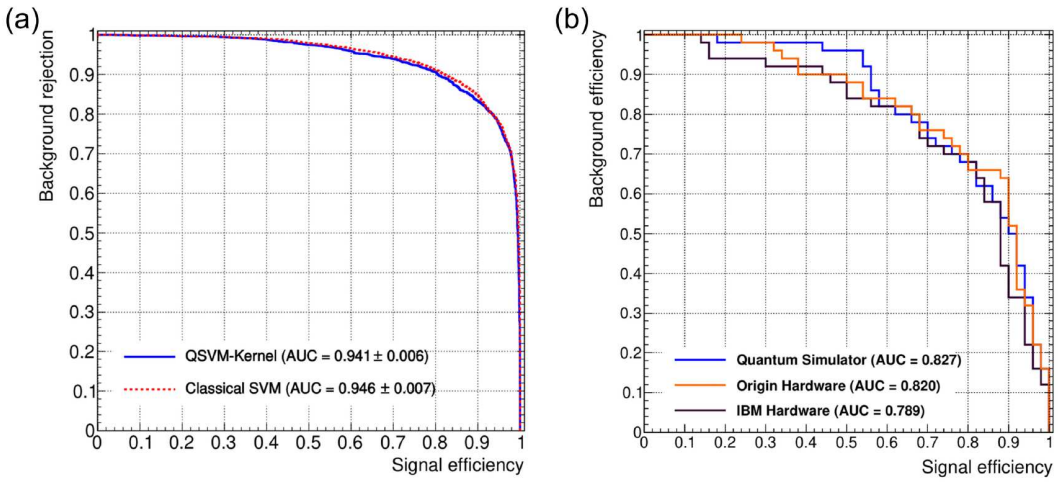


图 3 (a) 使用包含12000个事件的分析数据集绘制的机器学习分类器ROC曲线. 图中叠加了QSVM-Kernel算法(蓝色)和经典SVM算法(红色)的结果[24]. (b) 基于IBM Nairobi量子计算机硬件、本源Wuyuan量子计算机硬件及量子计算机模拟器的QSVM-Kernel分类器ROC曲线(使用相同$e^+e^- \to ZH$分析数据集)[24]

Figure 3 (a) The ROC curves of machine learning classifiers using the analysis dataset with 12000 events. The plot overlays the results of the QSVM-Kernel algorithm (blue) and the classical SVM algorithm (red)[24]. (b) The ROC curves of the QSVM-Kernel classifiers from the IBM Nairobi quantum computer hardware, the origin Wuyuan quantum computer hardware, and the quantum computer simulators with the same $e^+e^- \to ZH$ analysis dataset[24]

模的变化. 可以看到, 该差值在整个扫描区间内围绕零点小幅波动, 且幅度基本处于实验给出的统计不确定度范围之内, 未呈现出随样本规模显著扩大的趋势. 该现象表明, 在当前选取的六维输入特征与量子特征映射方案下, 量子核方法在判别能力上与经典核方法总体相当, 同时在数据规模变化方面表现出良好的稳健性与可泛化性. 这一点也与在LHC上利用量子核方法和其他量子机器学习模型进行事件分类的多项研究结论相一致[45~47].

3.3 总结与拓展

根据工作二对不同量子比特规模、特征映射与硬件运行结果的比较, 可以将QSVM–Kernel在高能物理事例分类中的作用概括为: 在喷注聚类完成后, 以量子特征映射构造面向事例级判别的核函数, 并将核矩阵交由经典SVM完成最大间隔训练. 与端到端变分分类器相比, 该路线保留了核方法在小样本与强正则条件下的稳健性与可解释性[36,37], 同时利用量子增强特征空间提供的高维表示能力, 改变信号与背景在特征空间中的相对几何结构, 从而在不牺牲训练可控性的前提下提升非线性可分性[12,13,22,37].

QSVM–Kernel的创新主要体现在特征空间构造而非分类器求解本身, 即经典端优化仍遵循标准SVM框架, 其差异集中在如何设计或选择量子特征映射以生成更具物理判别力的相似性度量. 因此, 在面向高能物理实际分析时, 评价标准不宜局限于单一的AUC指标, 而应建立一套可复现、可校准的实验流程. 具体而言, 在明确事例级输入表征及相应预处理方案的基础上, 通过交叉验证对量子核映射结构与正则化参数进行系统选择; 同时, 将有限shot采样引入的统计波动以及硬件噪声对核估计的影响一并纳入不确定度评估. 最终, 分类器输出以连续判别变量的形式并入后续拟合与系统学分析, 从而使量子核方法在整体上与高能物理标准统计推断流程保持一致[7,9,42,43].

针对QSVM–Kernel算法本体, 其未来可沿三条主线发展. 第一, 融入物理先验的特征映射设计, 将对称性与不变性约束编码进线路结构, 以提升跨能标泛化并抑制对非物理涨落的过拟合[12,37]; 第二, 面向大样本训练的核矩阵可扩展性, 通过低秩近似、代表点抽样或分块估计等方法缓解$O(N^2)$瓶颈, 从而将量子调用预算集中在信息增益更高的子空间[19,22]; 第三, 建立从核估计到分类边界再到物理量提取的不确定度传播框架, 使有限shot引入的统计涨落及硬件噪声造成的系统性偏差在分析层面可被量化与校准, 从而保证量子核方法的输出在可复现性与可解释性方面满足精密测量的要求[13,19,42,43].

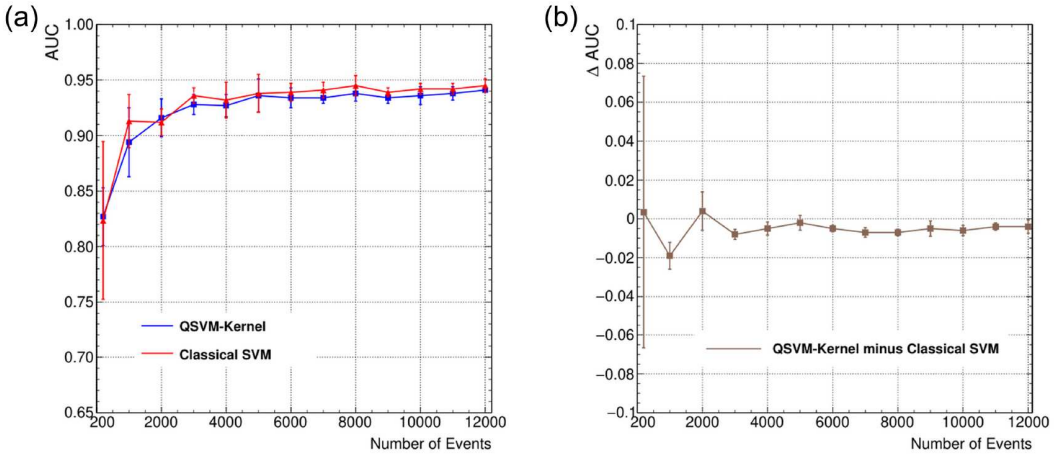


图 4 针对$e^+e^- \to ZH$分析, QSVM核方法与经典SVM分类器在不同数据集规模(200个事件及1000~12000个事件范围)下的AUC表现[24]. (a) 叠加展示了QSVM核方法与经典SVM的AUC结果随数据集规模变化的函数关系. (b) QSVM核算法与经典SVM算法之间的AUC差值, 该差值同样作为数据集规模的函数进行展示. 标注的AUC值为数据集多次随机重排后AUC结果的均值, 误差线则表示这些重排AUC值的标准偏差

Figure 4 The AUCs of the QSVM-Kernel and classical SVM classifiers for the $e^+e^- \to ZH$ analysis with different dataset sizes of 200 and from 1000 to 12000 events[24]. (a) The AUC results of the QSVM-Kernel and the classical SVM as a function of the dataset size. (b) The difference in AUC between the QSVM-Kernel algorithm and the classical SVM algorithm, again as a function of the dataset size. The quoted AUCs are the mean for the AUCs of several shuffles for the dataset, and the quoted errors are the standard deviations for the AUCs of the shuffles

4 讨论与展望

量子计算正在成为高能物理在后摩尔时代探索新型算力形态的重要选项之一. 本文前述的两类代表性应用分别对应分析链中的两种关键计算环节, 为评估量子计算在真实物理任务中的可行性提供了早期样例[12,13]. 需要强调的是, 决定量子计算能否在高能物理中形成可持续且可用的增益, 根本上取决于量子硬件能力、系统软件栈与统计推断需求之间的匹配与协同, 不仅要在有限规模上跑通算法, 更要保证在更大统计量、更严格系统学约束下仍具有可复现和可验证的不确定度控制能力.

主流量子处理器仍处于NISQ阶段, 可用规模并不由量子比特数单独决定, 相干时间、单比特门操作误差、两比特门操作误差与读出误差、器件连通拓扑结构引起的拓扑映射代价以及串扰与漂移导致的时变噪声会共同限制可执行线路深度与有效纠缠资源[48]. 对高能物理应用而言, 这些限制的影响往往体现在重复调用的场景, 因同一子程序需要在大统计量下反复执行, 故任何小幅漂移都可能在长期运行中积累为可观偏差. 因此, 硬件误差应当被表述为可量化、可跟踪的不确定度来源, 并在后续统计推断中得到一致性处理. 实践层面更关键的问题是在给定硬件条件与采样预算下, 量子输出能否稳定到足以支撑分析链条对可复现性与可解释性的要求.

随着硬件的发展, 短期内器件层面的改进主要体现为相干时间的提升、门控操作与读出保真度的提高, 以及对串扰与漂移的抑制, 从而扩大可用线路深度并改善长期运行的可维护性[49]. 同时, 伴随体系结构能力的提升, 会出现更合理的耦合与互连方式, 以及对中途测量、快速复位与经典前馈控制的支持. 这些能力会影响并行度、吞吐与作业调度方式, 也决定了量子处理器能否以“协处理器”的形式稳定接入现实工作流. 更长远的方向是容错量子计算, 量子纠错与编码在原理上可以将错误率压低到支持大规模可靠运算的水平, 但其实现需要更高的物理保真度、更强的实时测控能力以及显著的资源冗余[50]. 在NISQ向容错过渡的阶段, 量子误差缓解与噪声自适应编译预计仍会是常用手段. 它们的重要性不在于提供严格的容错保证, 而在于把噪声效应转化为可建模、可传播的不确定度成分, 使量子输出能够以更一致的方式进入统计推断流程.

量子计算若要在未来对撞机实验中形成可部署的分析能力, 还必须与现有高能物理计算栈实现工程化协同. 高能物理数据处理具有海量事件、复杂预处理与强统计推断的特征, 量子处理器更现实的作用是作为加速器嵌入现有高性能计算(high performance computing, HPC)与分布式工作流, 而不是替代成熟的经典体系. 为实现工程化落地, 主要还需进行两方面工作: 一是面向物理任务建立可复现的基准与工作流对接标

准，把量子调用成本、硬件漂移与量子误差缓解策略对输出的影响明确映射到分析不确定度；二是在系统层面提升作业调度、吞吐与跨平台的一致性，使量子模块能够稳定服务于大规模统计分析. 随着硬件规模、保真度与系统软件能力的持续发展，预计量子计算在粒子相互作用与量子场论模拟[51,52]以及更大规模对撞数据处理等方向的研究空间仍将扩展[53]. 在CEPC、FCC-ee、高亮度LHC等未来实验对高强度数据处理与高精度分析提出更高要求的背景下，量子计算作为补充性算力资源是否可用，最终取决于硬件条件、系统软件与统计推断三者能否形成一致的误差管理与复现标准.

参考文献

1 Gligorov V. Real-time data analysis at the LHC: present and future. In: Cowan G, Germain C, Guyon I, et al., eds. Proceedings of the NIPS 2014 Workshop on High-energy Physics and Machine Learning. Montreal, Canada: PMLR, 2015. 1–18
2 Guimarães da Costa J B, Li H, Zhang Z, et al. CEPC Conceptual Design Report: Volume 2 – Physics & Detector. 2018
3 Abada A, Abbrescia M, AbdusSalam S S, et al. FCC-ee: the Lepton collider. Eur Phys J Spec Top, 2019, 228: 261–623
4 Baer H, Barklow T, Fujii K, et al. The International Linear Collider Technical Design Report – Volume 2: Physics. SLAC-R-1004, 2013
5 Sirunyan A M, Tumasyan A, Adam W, et al. Particle-flow reconstruction and global event description with the CMS detector. J Inst, 2017, 12: P10003
6 Cacciari M, Salam G P, Soyez G. The anti-k_t jet clustering algorithm. J High Energy Phys, 2008, 2008(4): 063
7 Radovic A, Williams M, Rousseau D, et al. Machine learning at the energy and intensity frontiers of particle physics. Nature, 2018, 560: 41–48
8 Kourlitis V, Leontaris G, Tsarouchas C, et al. HL-LHC and beyond computing challenges. In: Proceedings of the Eleventh Annual Conference on Large Hadron Collider Physics — PoS(LHCP2023), 2024, doi: 10.22323/1.450.0112
9 Albrecht J, Alves Jr A A, Amadio G, et al. A roadmap for HEP software and computing R&D for the 2020s. Comput Softw Big Sci, 2019, 3
10 Sjöstrand T, Ask S, Christiansen J R, et al. An introduction to PYTHIA 8.2. Comput Phys Commun, 2015, 191: 159–177
11 Jia W, Sun M, Lian J, et al. Feature dimensionality reduction: a review. Complex Intell Syst, 2022, 8: 2663–2693
12 Wu Y, Schermer M, Leib M, et al. Application of quantum machine learning to high energy physics data analysis: a review. Mach Learn Sci Technol, 2023, 4: 023001
13 Preskill J. Quantum Computing in the NISQ era and beyond. Quantum, 2018, 2: 79
14 Shor P W. Algorithms for quantum computation: discrete logarithms and factoring. In: Proceedings of the 35th Annual Symposium on Foundations of Computer Science. IEEE, 1994. 124–134
15 Grover L K. A fast quantum mechanical algorithm for database search. In: Proceedings of the 28th Annual ACM Symposium on Theory of Computing. ACM, 1996. 212–219
16 Arute F, Arya K, Babbush R, et al. Quantum supremacy using a programmable superconducting processor. Nature, 2019, 574: 505–510
17 Blance A, Spannowsky M. Quantum machine learning for particle physics using a variational quantum classifier. J High Energ Phys, 2021, 2021 (2): 212
18 Cerezo M, Arrasmith A, Babbush R, et al. Variational quantum algorithms. Nat Rev Phys, 2021, 3: 625–644
19 Bharti K, Cervera-Lierta A, Kyaw T H, et al. Noisy intermediate-scale quantum algorithms. Rev Mod Phys, 2022, 94: 015004
20 Klco N, Dumitrescu E F, McCaskey A J, et al. Quantum-classical computation of Schwinger model dynamics using quantum computers. Phys Rev A, 2018, 98: 032331
21 Farhi E, Goldstone J, Gutmann S. A quantum approximate optimization algorithm. 2012, arXiv: 1411.4028
22 Havlíček V, Córcoles A D, Temme K, et al. Supervised learning with quantum-enhanced feature spaces. Nature, 2019, 567: 209–212
23 Zhu Y, Zhuang W, Qian C, et al. A novel quantum realization of jet clustering in high-energy physics experiments. Sci Bull, 2025, 70: 460–463
24 Fadol A, Sha Q Y, Fang Y Q, et al. Application of quantum machine learning in a Higgs physics study at the CEPC. 2024, arXiv: 2209.12788
25 Wilson K G. Confinement of quarks. Phys Rev D, 1974, 10: 2445–2459
26 Higgs P W. Broken symmetries, massless particles and gauge fields. Phys Lett, 1964, 12: 132–133
27 Englert F, Brout R. Broken symmetry and the mass of gauge vector mesons. Phys Rev Lett, 1964, 13: 321–323
28 Higgs P W. Spontaneous symmetry breakdown without massless bosons. Phys Rev, 1966, 145: 1156–1163
29 Guerreschi G G, Matsuura A Y. QAOA for Max-Cut requires hundreds of qubits for quantum speed-up. Sci Rep, 2019, 9: 6903
30 Albash T, Lidar D A. Adiabatic quantum computation. Rev Mod Phys, 2018, 90: 015002
31 Bonet-Monroig X, Wang H, Vermetten D, et al. Performance comparison of optimization methods on variational quantum algorithms. Phys Rev A, 2023, 107: 032407

32 Ikotun A M, Ezugwu A E, Abualigah L, et al. K-means clustering algorithms: a comprehensive review, variants analysis, and advances in the era of big data. Inf Sci, 2023, 622: 178–210

33 Cacciari M, Salam G P, Soyez G. FastJet user manual. Eur Phys J C, 2012, 72: 1896

34 Siraichi M Y, Santos V F, Collange C, et al. Qubit allocation. In: Proceedings of the 2018 IEEE/ACM International Symposium on Code Generation and Optimization (CGO 2018). New York: Association for Computing Machinery, 2018. 113–125

35 Zulehner A, Paler A, Wille R. Efficient mapping of quantum circuits to the IBM QX architectures. In: Proceedings of the 2018 Design, Automation and Test in Europe Conference and Exhibition (DATE 2018). Piscataway: Institute of Electrical and Electronics Engineers, 2018. 1135–1138

36 CMS Collaboration. The Phase-2 Upgrade of the CMS Level-1 Trigger: Interim Technical Design Report. Geneva: CERN, 2017. Report No. CERN-LHCC-2017-013, CMS-TDR-017

37 Schuld M, Killoran N. Quantum machine learning in feature Hilbert spaces. Phys Rev Lett, 2019, 122: 040504

38 Boser B E, Guyon I M, Vapnik V N. A training algorithm for optimal margin classifiers. In: Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory. New York: Association for Computing Machinery, 1992. 144–152

39 Cortes C, Vapnik V. Support-vector networks. Mach Learn, 1995, 20: 273–297

40 Aleksandrowicz G, Alexander T, Barkoutsos P, et al. Qiskit: an open-source framework for quantum computing (EB/OL). 2019, doi:10.5281/zenodo.2562111

41 Chen Z Y, Guo G P. QPanda: a quantum programming framework. 2019, arXiv: 1901.08340

42 Allen D M. The relationship between variable selection and data agumentation and a method for prediction. Technometrics, 1974, 16: 125–127

43 Stone M. Cross-validatory choice and assessment of statistical predictions. J R Statistical Soc Ser B-Statistical Methodology, 1974, 36: 111–133

44 Pedregosa F, Varoquaux G, Gramfort A, et al. Scikit-learn: machine learning in Python. J Mach Learn Res, 2011, 12: 2825–2830

45 Wu S L, Sun S, Guan W, et al. Application of quantum machine learning using the quantum kernel algorithm on high energy physics analysis at the LHC. Phys Rev Res, 2021, 3: 033221

46 Terashi K, Kaneda M, Kishimoto T, et al. Event classification with quantum machine learning in high-energy physics. Comput Softw Big Sci, 2021, 5: 2

47 Heredge J, Hill C, Hollenberg L, et al. Quantum support vector machines for continuum suppression in B meson decays. Comput Softw Big Sci, 2021, 5: 27

48 Shor P W. Scheme for reducing decoherence in quantum computer memory. Phys Rev A, 1995, 52: R2493–R2496

49 Chen Y, Neill C, Roushan P, et al. Qubit architecture with high coherence and fast tunable coupling. Phys Rev Lett, 2014, 113: 220502

50 Ofek N, Petrenko A, Heeres R, et al. Extending the lifetime of a quantum bit with error correction in superconducting circuits. Nature, 2016, 536: 441–445

51 Bauer C W, Davoudi Z, Klco N, et al. Quantum simulation of fundamental particles and forces. Nat Rev Phys, 2023, 5: 420–432

52 Bauer C W, Nachman B, Freytsis M. Simulating collider physics on quantum computers using effective field theories. Phys Rev Lett, 2021, 127: 212001

53 Brehmer J. Simulation-based inference in particle physics. Nat Rev Phys, 2021, 3: 305

Summary for “高能物理中的量子可行性验证与优势探索: 喷注重建与事例分类的前沿算法”

Quantum feasibility verification and advantage exploration in high-energy physics: frontier algorithms for jet reconstruction and event classification

Yongfeng Zhu[1†], Jinzhe Wu[2†] & Chen Zhou[3*]

[1] *Institute of High Energy Physics, Chinese Academy of Sciences, Beijing 100049, China*
[2] *School of Physics, Jilin University, Changchun 130012, China*
[3] *State Key Laboratory of Nuclear Physics and Technology, School of Physics, Peking University, Beijing 100871, China*
† Equally contributed to this work
* Corresponding author, E-mail: czhouphy@pku.edu.cn

High-energy physics (HEP) experiments have fully entered a data-intensive era in which event sizes, detector granularity, and analysis complexity are increasing rapidly. These trends impose growing pressure on conventional computing in multiple parts of the reconstruction-and-analysis chain. In particular, classical methods can exhibit practical bottlenecks when confronted with high-dimensional feature spaces, intrinsically combinatorial decision making, and the need to process massive datasets under stringent throughput constraints. Quantum computing, exploiting quantum superposition and entanglement, provides a complementary computational paradigm that may help address such challenges by enabling new algorithmic routes for optimization and learning, especially through hybrid quantum–classical workflows suitable for near-term devices.

This article reviews two representative lines of recent progress on quantum algorithms for HEP data analysis. The first focuses on jet clustering, which is translated into a combinatorial optimization problem. Final-state particles are mapped to vertices of a weighted graph, where edge weights encode geometric relations (e.g., angular separation) and circuit resources are controlled via k-nearest-neighbor sparsification. The clustering objective is then reformulated as a Max-Cut instance and encoded into an Ising-type Hamiltonian. A quantum approximate optimization algorithm (QAOA) alternates cost and mixer evolutions within a shallow parameterized circuit, while a classical optimizer iteratively updates circuit parameters based on repeated measurements of the objective. Small-scale studies demonstrate that QAOA-based jet clustering, via a Max-Cut mapping, establishes the feasibility of hybrid quantum–classical optimization for event reconstruction on current hardware within statistical uncertainties in practice.

The second application targets Higgs event classification in the context of a circular electron–positron collider (CEPC) using quantum kernel methods. A quantum support vector machine with a kernel (QSVM-kernel) embeds compact kinematic feature vectors into a quantum feature space through a designed feature-map circuit. Quantum circuits are used to estimate kernel matrix elements on hardware (or calibrated noisy simulators), after which a classical support vector machine (SVM) solves the associated convex optimization problem in kernel space. For benchmark CEPC Higgs analyses with low-dimensional inputs, the quantum-kernel classifier achieves signal–background discrimination comparable to classical kernel SVMs, and the workflow can be executed stably on current superconducting platforms at the relevant qubit scales.

Despite the fact that present-day quantum hardware remains constrained by noise, limited qubit counts, and decoherence, a growing body of frontier studies has already validated the feasibility of quantum algorithms on small-scale tasks such as jet reconstruction and event classification, while also initiating preliminary investigations toward potential quantum advantage. With continued improvements in hardware fidelity, the maturation of quantum error mitigation techniques, and the development of scalable divide-and-conquer strategies, quantum computing is expected to play an increasingly important role in future data processing and analysis pipelines of high-energy physics experiments.

quantum computing, quantum optimization, quantum machine learning, high-energy physics, jet reconstruction, event classification

doi: 10.1360/CSB-2025-5947