

专题: 量子光学原理与应用

# 量子人工智能: 人工智能与量子计算的双向赋能机制与前沿进展

杨君侠<sup>1)</sup> 蔡淇智<sup>1)</sup> 郭晋荣<sup>1)</sup> 邓光伟<sup>1)2)3)4)5)†</sup>

1) (电子科技大学基础与前沿研究院, 成都 610054)

2) (电子科技大学, 量子物理与光子量子信息教育部重点实验室, 成都 610054)

3) (中国科学技术大学, 量子信息重点实验室, 合肥 230026)

4) (合肥国家实验室, 合肥 230088)

5) (新疆高等师范专科学校, 乌鲁木齐 830043)

(2025年12月30日收到; 2026年2月13日收到修改稿)

经典计算正逼近物理极限, 而含噪声的中等规模量子硬件面临校准与控制瓶颈, 这催化了量子人工智能这一前沿交叉领域的诞生. 量子人工智能旨在利用人工智能与量子计算的协同作用, 解决彼此的瓶颈问题. 本综述系统地分析量子人工智能的双向赋能框架. 在“AI for Quantum”方面, AI正成为克服中等规模量子硬件瓶颈的工具, 关键应用包括设备自动化校准与高保真读出、开发超越传统算法的AI量子纠错解码器及AI驱动的量子线路优化. 在“Quantum for AI”方面, 量子计算正为AI算法提供新的计算范式与模型设计思路, 从早期的HHL, QSVM算法演进到中等规模量子时代主流的变分量子算法和量子神经网络, 同时综述了该领域面临的贫瘠高原等可训练性挑战及其缓解策略, 并涵盖了量子优化及量子原生智能模型. 总结指出, 量子人工智能的双向融合有望成为推动量子计算从中等规模量子时代迈向容错计算、构建下一代混合量子-经典智能系统的重要路径之一.

**关键词:** 量子人工智能, 量子计算, 人工智能**DOI:** 10.7498/aps.75.20251792**CSTR:** 32037.14.aps.75.20251792

## 1 引言

以摩尔定律<sup>[1,2]</sup>为代表的经典计算正逼近其物理极限, 推动量子计算发展<sup>[3]</sup>. 量子计算的核心是量子比特 (Qubit), 它利用“叠加”特性同时处于0和1态<sup>[4]</sup>, 并通过纠缠现象产生精密的非局域关联<sup>[5]</sup>. 这两种特性共同构建了一个随量子比特数呈指数级增长的计算空间, 有望解决经典计算机无法应对的难题, 如新药发现、复杂优化、破解现代密码 (Shor 算法<sup>[6]</sup>) 及通过量子模拟革新材料科学<sup>[7]</sup>. 然而, 量子计算仍处于含噪声的中等规模量子 (noisy intermediate-scale quantum, NISQ) 时代, 其硬件

受限于有限的量子比特和高错误率<sup>[8]</sup>, 存在包括对抗量子退相干<sup>[9]</sup>及量子纠错<sup>[10]</sup>等挑战.

在应对这些挑战时, 人工智能 (artificial intelligence, AI) 展现出独特优势<sup>[11]</sup>. 如机器学习凭借其强大的模式识别与策略优化能力, 被广泛用于提升NISQ硬件性能, 从量子比特自动校准和优化门保真度<sup>[12]</sup>, 到辅助量子线路设计以及纠错解码<sup>[13]</sup>. 同时, “Quantum for AI”方向也已出现, 即利用量子设备的独特能力来应对AI领域的挑战. 量子计算机处理高维线性空间和复杂概率分布的内在能力与现代AI的核心需求高度吻合. 该方向主要包括量子机器学习 (利用量子特征空间增强数据分析与模式识别<sup>[14]</sup>) 和量子优化 (利用量子退火<sup>[15]</sup>或量

† 通信作者. E-mail: gw deng@uestc.edu.cn

子近似优化算法<sup>[16]</sup>等解决复杂的组合优化问题。

这种双向赋能共同定义了一个前沿交叉学科领域: 量子人工智能 (quantum artificial intelligence, QAI)<sup>[17]</sup>. 本文遵循从基础物理原理到双向赋能应用的逻辑进行讨论. 第 2 节回顾量子计算的核心物理原理与主要计算模型, 第 3 节聚焦于人工智能如何作为一种强大的工具来优化和加速量子技术的发展, 即“AI for Quantum”, 第 4 节探讨如何利用量子计算独特的处理能力来革新人工智能算法本身, 即“Quantum for AI”, 最后对 QAI 领域的现状与未来进行总结与展望.

## 2 量子计算

### 2.1 量子计算的核心原理

#### 2.1.1 量子比特与叠加态

量子计算的基本单位——Qubit 可处于量子叠加态<sup>[18]</sup>:

$$|\varphi\rangle = \alpha|0\rangle + \beta|1\rangle,$$

其中系数  $\alpha$  和  $\beta$  是复数概率幅, 必须满足归一化条件:

$$|\alpha|^2 + |\beta|^2 = 1.$$

测量叠加态  $|\varphi\rangle$  时, 其状态会“坍缩”<sup>[18]</sup>, 以  $|\alpha|^2$  的概率得到“0”,  $|\beta|^2$  的概率得到“1”.

多量子比特系统的状态空间是其子系统空间的张量积<sup>[18]</sup>. 量子比特的叠加态是量子计算超越经典的关键所在<sup>[19]</sup>.  $n$  个经典比特组成的寄存器只能表示  $2^n$  个状态之一. 而  $n$  个量子比特寄存器可同时表示所有  $2^n$  个状态的相干叠加<sup>[18]</sup>. 因此, 对  $n$  量子比特系统的一次操作, 等同于同时对  $2^n$  个状态进行操作, 量子算法通过幺正演化和干涉机制调控各基态振幅, 使目标解在测量中以较高概率出现, 这种基于量子相干与干涉的独特并行演化能力<sup>[19]</sup>,

使量子计算机在解决大数分解、量子模拟等特定问题时展现出巨大优势<sup>[6]</sup>.

#### 2.1.2 量子纠缠

当多量子比特系统的状态无法分解为各子系统状态的张量积时, 该系统便处于纠缠态<sup>[5]</sup>.

一般描述  $N$  量子比特的纠缠态需  $N$  的指数级个复数系数, 而可分离态仅需线性个. 这种指数级的参数空间是量子计算获得超越性算力的关键<sup>[20]</sup>, 使其计算空间从经典可模拟的线性角落, 扩展到了指数尺度的希尔伯特空间.

#### 2.1.3 量子操作与测量

一个完整的计算模型还需包含两大过程: 执行计算的量子操作和提取信息的量子测量<sup>[18]</sup>. 根据量子力学, 封闭量子系统的状态演化由幺正变换 (unitary transformation) 描述<sup>[18]</sup>. 幺正变换具有两大核心性质: 1) 可逆性 (存在逆变换  $U^\dagger$ ), 确保计算过程中信息不丢失; 2) 概率守恒, 确保量子态在演化后概率和仍为 1. 量子操作的结果仍是无法直接读取的叠加态, 因此必须通过量子测量来提取经典信息<sup>[18]</sup>. 测量本质上是概率性的, 遵循玻恩定则 (从状态  $|\varphi\rangle = \sum_i c_i |i\rangle$  中测量出基矢  $|j\rangle$  的概率为  $P(j) = |c_j|^2$ ). 更重要的是, 测量是一个非幺正、不可逆的过程, 会引发状态坍缩.

## 2.2 量子计算的主要模型

### 2.2.1 量子门模型

量子门模型是量子计算领域中最被广泛研究和接受的计算模型之一<sup>[18]</sup>. 它借鉴经典逻辑门概念, 将复杂计算分解为一系列基本“量子门”(幺正变换) 的有序组合. 如图 1 所示, 量子门模型的计算过程可以划分为三个基本阶段<sup>[18]</sup>:




图 1 量子门模型计算过程示意图<sup>[18]</sup>

Fig. 1. Schematic of the quantum gate model computation process<sup>[18]</sup>.

1) 初始化: 将  $n$  个量子比特制备到确定的初始状态. 通常为  $|00 \cdots 0\rangle$ .

2) 计算演化: 核心阶段. 通过量子线路图将一系列量子门 (幺正变换) 按顺序作用于量子比特. 此过程是确定且可逆的, 通过演化使解所对应的基态分量具有极高的概率幅.

3) 测量: 对演化后的最终态进行测量. 由于演化设计, 测量结果将以高概率给出答案 (常需多次运行统计得到确定性结果).

简而言之, 量子门模型通过离散量子门引导系统演化, 最终将计算结果以高概率编码在某个可测量的基态上.

### 2.2.2 绝热量子计算

绝热量子计算 (adiabatic quantum computation, AQC) 是传统门模型的一种通用替代方案 [21]. 其思想源于量子绝热定理 [22], 若系统哈密顿量  $H(t)$  变化足够缓慢, 初始处于基态的系统, 遵循含时薛定谔方程:

$$i\hbar \frac{d}{dt} |\varphi(t)\rangle = H(t) |\varphi(t)\rangle. \quad (1a)$$

演化时, 将始终近似保持在瞬时哈密顿量的基态上.

演化时间可由系统基态  $E_0(s)$  与第一激发态  $E_1(s)$  间的最小能量差, 即最小谱隙  $g_{\min}$  决定 [23]. 总演化时间  $T$  通常与谱隙倒数的某个幂次方成反比, 如  $T = O(1/g_{\min}^2)$  或  $T = O(1/g_{\min}^3)$ . AQC 将演化严格约束在瞬时基态所定义的路径上, 引导计算从简单初态演化至编码问题解的复杂末态 [21].

绝热量子计算的核心结构可分解为三个关键部分 [23], 如图 2 所示:

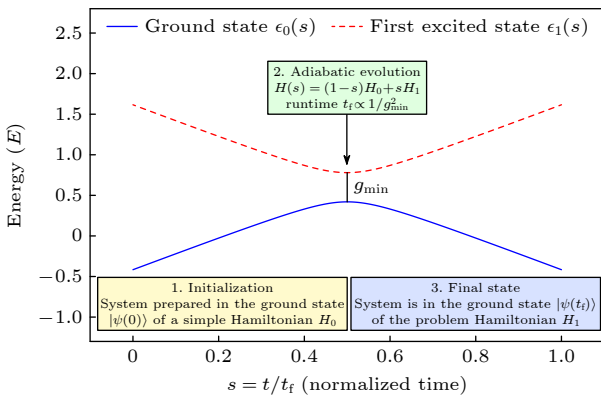


图 2 绝热量子计算框架示意图

Fig. 2. Schematic diagram of the adiabatic quantum computing framework.

1) 初始  $k$ -local 哈密顿量 ( $H_0$ ): 构造简单、基态易于制备. 常用  $H_0 = -\sum_i \sigma_i^x$ , 其中  $\sigma_i^x$  是作用在第  $i$  个量子比特上的泡利  $X$  算符. 其基态是计算基态的均匀叠加态  $|\varphi(0)\rangle = |+\rangle^{\otimes n}$ , 代表对解空间所有可能解的无偏探索起点.

2) 解  $k$ -local 哈密顿量 ( $H_1$ ): 其基态直接编码了待求解问题的最优解 (通常在  $Z$  基下对角化).

3) 绝热演化路径 ( $H(t)$ ): 随时间平滑变化的哈密顿量, 在  $t=0$  等于  $H_0$ , 在  $t=T$  等于  $H_1$ , 在两者之间实现平滑插值. 最简单且最常见的演化路径是线性插值:

$$H(s) = (1-s)H_0 + sH_1, \quad (1b)$$

其中  $s = t/T$  是归一化的时间参数.

AQC 与标准量子门模型的多项式等价性奠定了其作为通用计算模型的地位 [24]. 两者可以相互高效模拟.

### 2.2.3 单向量子计算

单向量子计算模型 (one-way quantum computation), 又称为基于测量的量子计算 (measurement-based quantum computation, MBQC) [25], 其核心思想是: 计算资源是一个预先制备的高度纠缠态, 计算过程则通过对该状态进行一系列单比特测量来驱动 [26].

如图 3 所示, 该模型分为两个阶段 [27]:

1) 资源准备阶段: 制备一个大规模、高度纠缠的“簇态”. 簇态是一种图态  $G = (V, E)$  [28]. 其制备方法是: 为每个顶点  $i \in V$  初始化到  $|+\rangle = (1/\sqrt{2}) \times (|0\rangle + |1\rangle)$  态, 并对每条边  $(i, j) \in E$  施加受控- $Z$  门操作 [29]. 簇态  $|\Phi_C\rangle$  可以用稳定子形式 [30] 来描述, 对于每个量子比特  $a$ , 存在稳定子生成元  $K_a = X_a \prod_{b \in N(a)} Z_b$ , 使得  $K_a |\Phi_C\rangle = |\Phi_C\rangle$ . 其中  $X_a$  和  $Z_a$  是作用在相应量子比特上的泡利- $X$  和泡利- $Z$  算符,  $N(a)$  是与量子比特  $a$  相邻 (有边连接) 的量子比特集合.

2) 计算执行阶段: 通过对簇态进行单比特投影测量来执行计算, 测量基的选择决定了逻辑操作. 如  $Z$  基测量用于“裁剪”簇态结构;  $X$  基测量用于传送量子态, 形成“量子线”;  $XY$  平面内的测量则用于实现任意单比特旋转门.

测量的空间布局和顺序决定了逻辑信息的流动, 将门模型中的时间序列映射为 MBQC 中的空

间布局<sup>[26]</sup>. 由于测量会产生随机的副产物算符, 为实现确定性计算, 必须采用“经典前馈”机制: 将前序的测量结果通过经典信道传递, 用以调整后续的测量基, 从而校正副产物. 这也为计算引入了必要的时间顺序<sup>[31]</sup>. 理论证明, 单向量子计算模型与量子门模型在计算能力上是等价的, 两者可以相互模拟<sup>[18,25]</sup>.

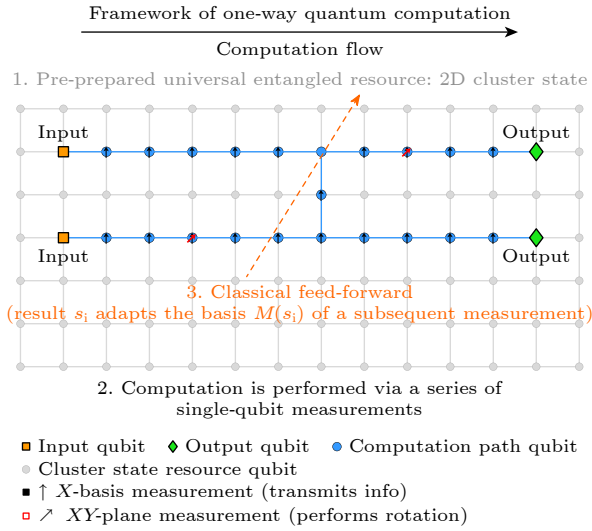


图 3 单向量子计算模型框架示意图

Fig. 3. Schematic diagram of the one-way quantum computation model.

### 2.2.4 拓扑量子计算

前三种模型都面临着一个挑战: 必须依赖复杂的、软件的量子纠错码和容错计算协议来进行实时的错误探测与纠正. 拓扑量子计算 (topological quantum computation, TQC) 提出了一种新的思路: 将信息非局域地编码于系统的全局拓扑结构中, 使其在硬件层面内禀地免疫局域噪声<sup>[32,33]</sup>, 具体流程如图 4 所示.

这一构想的核心是利用物质的拓扑相, 特别是存在“非阿贝尔任意子”(non-Abelian anyons) 的二维量子系统. 任意子是二维空间特有的奇异粒子, 其交换统计由非交换的“辫子群”描述<sup>[33]</sup>. 任意子可以被分为两大类: 阿贝尔任意子和非阿贝尔任意子. 阿贝尔任意子交换时只产生一个可交换的复相位, 不足以实现通用量子计算<sup>[33]</sup>. 当系统存在多个非阿贝尔任意子时, 其基态通常是简并的<sup>[34]</sup>, 构成一个“编码空间”. 交换非阿贝尔任意子会使系统状态在该子空间中发生一次幺正旋转 ( $U$ ). 关键在于, 这些操作是非对易的 (例如  $U_i U_j \neq U_j U_i$ ), 这使某些非阿贝尔任意子模型的编织操作能实现通

用的量子门<sup>[35]</sup>.

当信息被非局域地编码在简并基态中, 且该基态子空间与激发态之间存在一个有限的能隙  $\Delta E$ . 只要环境扰动远小于  $\Delta E$ , 任何局域噪声都无法区分这些拓扑状态, 也就无法导致退相干. 其错误率被预测随系统尺度  $L$  呈指数级下降 ( $e^{-L/\xi}$ )<sup>[32]</sup>. 拓扑量子计算过程包含三个基本步骤: 初始化、计算和测量. 通过局域操作, 从基态中产生任意子对, 构建出初始编码态. 然后绝热地交换任意子. 最终的幺正操作仅依赖于辫子的拓扑结构, 而与具体路径无关, 因此对控制误差高度鲁棒. 最后将任意子对融合, 通过测量融合通道来读出结果<sup>[35]</sup>. TQC 的核心优势在于其内禀的容错能力, 为构建可扩展的量子计算机提供了一条极具吸引力的途径<sup>[33]</sup>.

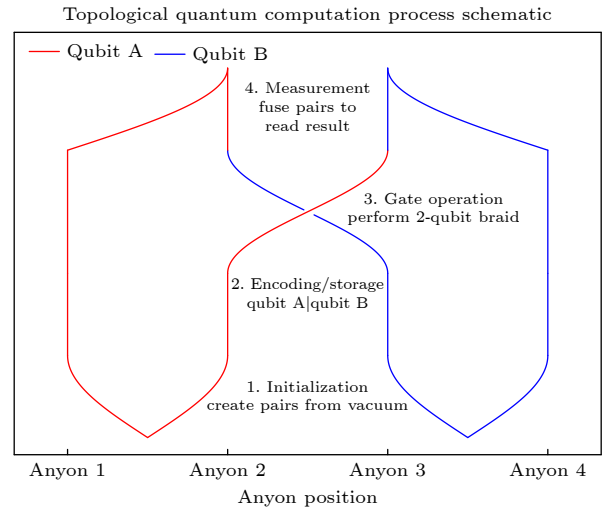


图 4 拓扑量子计算流程示意图

Fig. 4. Schematic diagram of the process of topological quantum computation.

### 2.3 从理论模型到物理实现的共同挑战

尽管上述四种模型范式各异, 但它们都共同面临一个根本挑战: 量子信息对环境噪声和控制误差极端敏感. 无论通过软件纠错还是硬件保护, 都尚未在复杂环境中实现对脆弱量子系统的高精度、鲁棒性控制. 在这一背景下, AI 的数据驱动建模与优化能力为缓解上述瓶颈提供了新的技术路径, 逐步形成了‘AI for Quantum’这一交叉研究方向.

## 3 AI for Quantum

AI, 特别是机器学习 (machine learning, ML) 的两大核心能力, 作为通用函数逼近器和高效优化




图 5 机器学习和人工智能可用于解决的量子技术任务概览<sup>[36]</sup>

Fig. 5. Overview of tasks in the area of quantum technologies that machine learning and AI can help solve<sup>[36]</sup>.

器, 高度契合了量子系统高维、含噪且难以精确建模的特性. AI 的逼近能力能学习量子模型以实现精准表征, 其优化能力则能自主发现超越直觉的策略, 用于优化量子电路和实验设计. 其涉及的任务概览如图 5 所示, 接下来, 本文将从量子设备的表征、校准与读出, 量子纠错与缓解, 量子电路优化与实验设计这三个方面, 阐述“AI for Quantum”的具体进展.

### 3.1 AI 用于量子设备表征、校准与读出

为实现容错量子计算, 通常需要数百万个物理量子比特来编码具有足够纠错能力的逻辑量子比特. 这种规模化带来了系统复杂性的指数级增长, 因此, 表征、校准和读出这些复杂系统的难度也随系统规模快速增长.

#### 3.1.1 表征

精确表征量子设备是实现高保真度量子控制的先决条件, 其核心目标是获得准确的数学模型, 通常是哈密顿量或林德布劳德算符及其噪声源. 传统表征方法面临缺乏可扩展性, 资源消耗呈指数增长; 简化模型则常无法捕捉复杂的真实错误等挑战.

AI 模型能从实验数据中学习复杂的高维映射. 在被动学习范式下, 模型从预先收集的数据中学习, 核心在于更高效准确地从数据中提取物理信息. 其中一个重要发展方向是物理知识引导的机器学习, 能显著提高效率和可解释性. 例如, É. Genois 等<sup>[37]</sup>的“量子定制”(quantum-tailored) 模型性能显著优于通用循环神经网络 (recurrent neural network, RNN) 模型 (图 6(a)). An 等<sup>[38]</sup>的长短期记忆网络具备预测动力学和推断哈密顿量的“双向能力”(图 6(b)). Ji 等<sup>[39]</sup>则提出了数据高效的噪声建模框架, 大幅减少开销并提高保真度 (图 6(c)).

更前沿的主动学习范式中, AI 智能体能主动

选择实验以最大化信息增益. Dutt 等<sup>[40]</sup>提出的哈密顿量主动学习 (Hamiltonian active learning, HAL) 算法便是其代表 (图 6(d)). 该算法以批处理模式运行, 通过基于费雪信息等准则来优化选择查询批次, 能以最少的测量次数达到目标精度. 实验证明, HAL 相比被动学习可减少 95% 以上的查询次数, 特定条件下甚至能超越标准量子极限, 达到海森伯极限的收敛速度.

#### 3.1.2 校准

量子设备的校准与调谐, 即在高维、非凸参数空间中找到最佳工作点, 是将其从物理系统转变为可用计算设备的关键, 传统手动或半自动方法耗时且难扩展.

如图 7 所示, 机器学习, 特别是深度学习、贝叶斯优化与强化学习, 正推动量子设备调谐的自动化. 一个从粗调到精调的 AI 技术栈正逐渐形成. 粗调阶段任务核心是快速识别设备所处的物理状态, 主要发展是利用卷积神经网络 (convolutional neural network, CNN) 分析二维“稳定性图”, 一种有效策略是“模拟到现实”的迁移学习: 在模拟数据上预训练 CNN 以分类设备状态, 然后将该模型部署于真实设备形成闭环反馈, 自主测量、分类并调整参数, 从而高效地将设备引导至目标工作区域. Zwolak 等<sup>[41]</sup>便成功实践了这一策略, 在真实设备中原位实现了双量子点状态的自动调谐.

精调阶段则依赖强化学习 (reinforcement learning, RL) 和贝叶斯优化等算法. Sarma 和 Hartmann<sup>[42]</sup>采用混合策略, 利用 RL 探索脉冲空间, 为梯度优化器提供优质初猜, 结合了 RL 的全局探索 and 最优控制的精调能力. 贝叶斯优化因其高样本效率而表现突出. Stace 等<sup>[43]</sup>开发的 OBSID 协议, 以比传统方法少 60 倍的测量次数达到更高精度. Moon 等<sup>[44]</sup>也利用类似统计算法, 在 70 min 内找到了最优性能点.

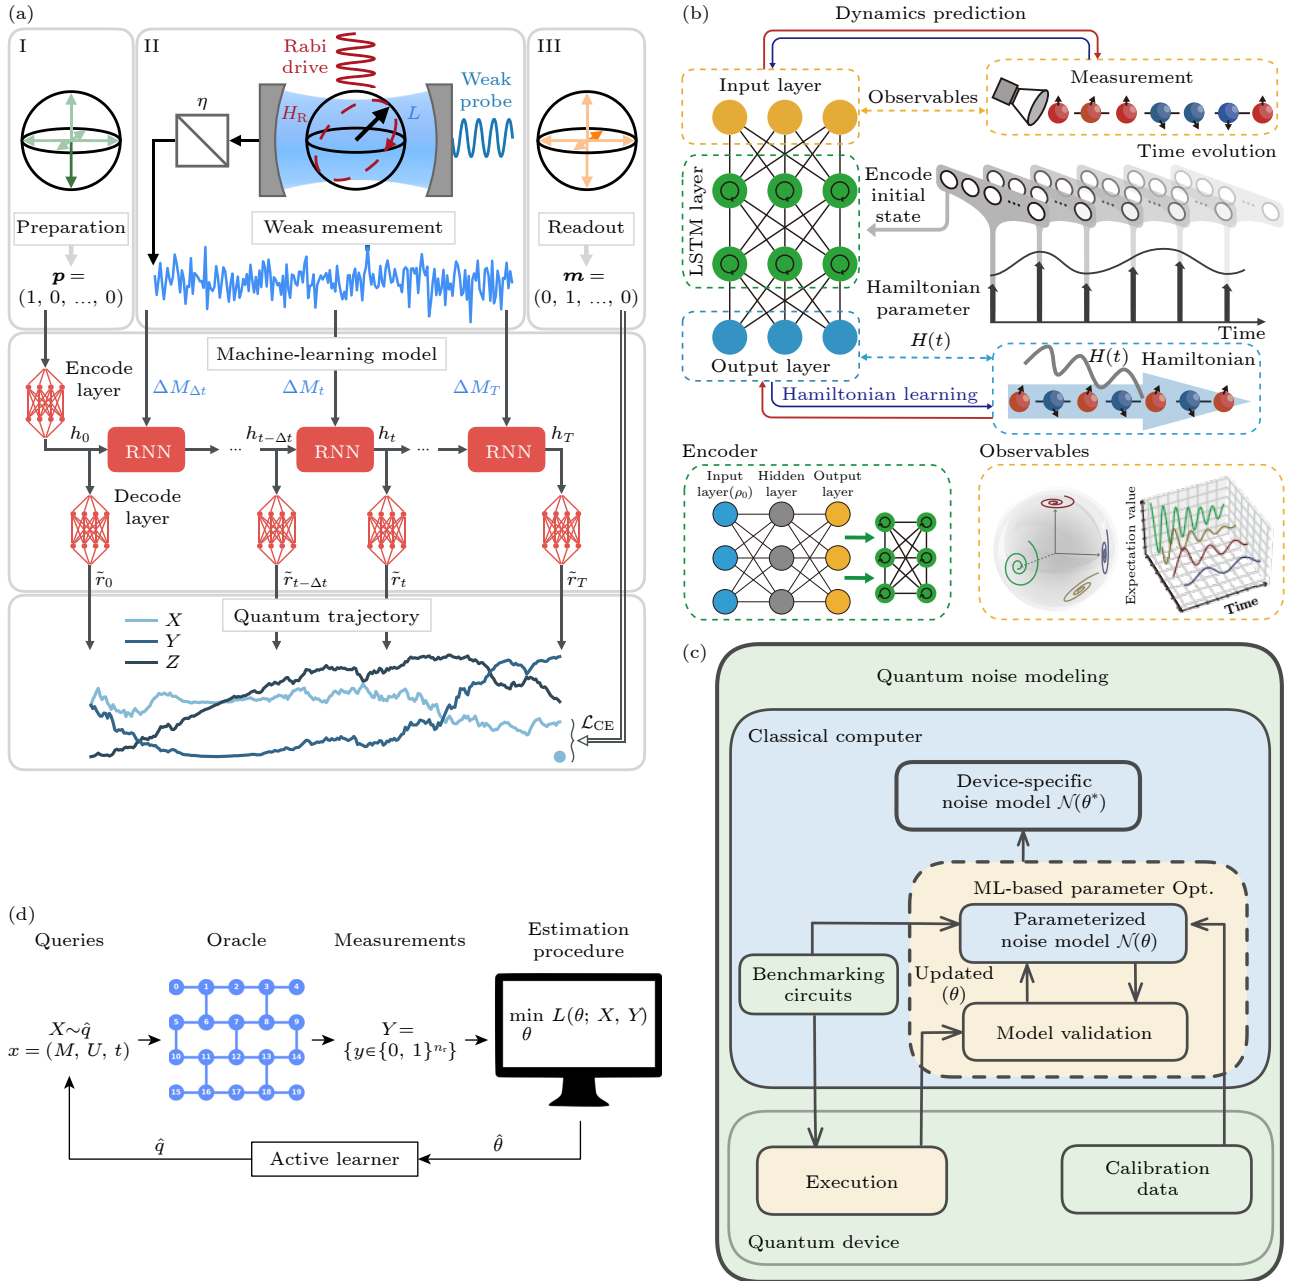


图 6 用于量子系统表征的先进机器学习模型概念图 (a) 物理知识引导的 RNN 重建量子轨迹<sup>[37]</sup>; (b) 长短期记忆网络模型用于动力学预测与哈密顿量推断<sup>[38]</sup>; (c) 数据高效的量子噪声建模<sup>[39]</sup>; (d) 主动学习哈密顿量框架<sup>[40]</sup>

Fig. 6. Conceptual diagrams of advanced machine learning models for quantum system characterization: (a) Physics-informed RNN for quantum trajectory reconstruction<sup>[37]</sup>; (b) long short-term memory for dynamics prediction and Hamiltonian inference<sup>[38]</sup>; (c) data-efficient quantum noise modeling<sup>[39]</sup>; (d) active learning framework for Hamiltonian<sup>[40]</sup>.

2024 年, Schuff 等<sup>[45]</sup> 首次实现了半导体自旋量子比特的完全自主调谐, 三天内完成专家需数周的任务, 集成了深度学习、贝叶斯优化和计算机视觉等多种技术. 针对更大规模超导处理器, Cao 等<sup>[46]</sup> 提出了 k-agents 多智能体框架, 利用大语言模型封装实验室知识, 成功实现了纠缠量子态的自主制备与表征. 这些进展共同证明结合多种 AI 技术的多层次自动化 workflows 正成为克服校准瓶颈、推

动量子计算规模化的关键.

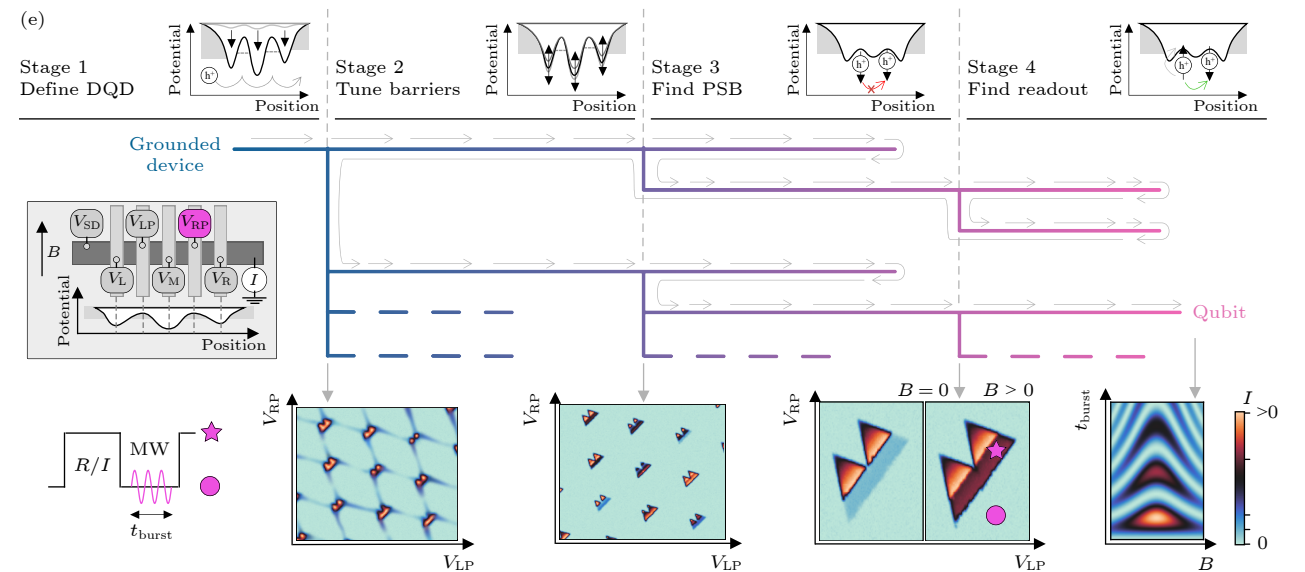
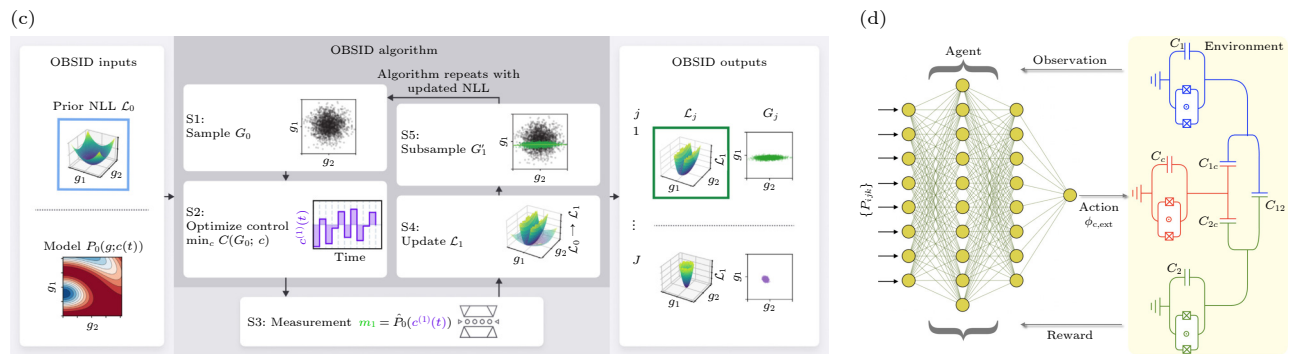
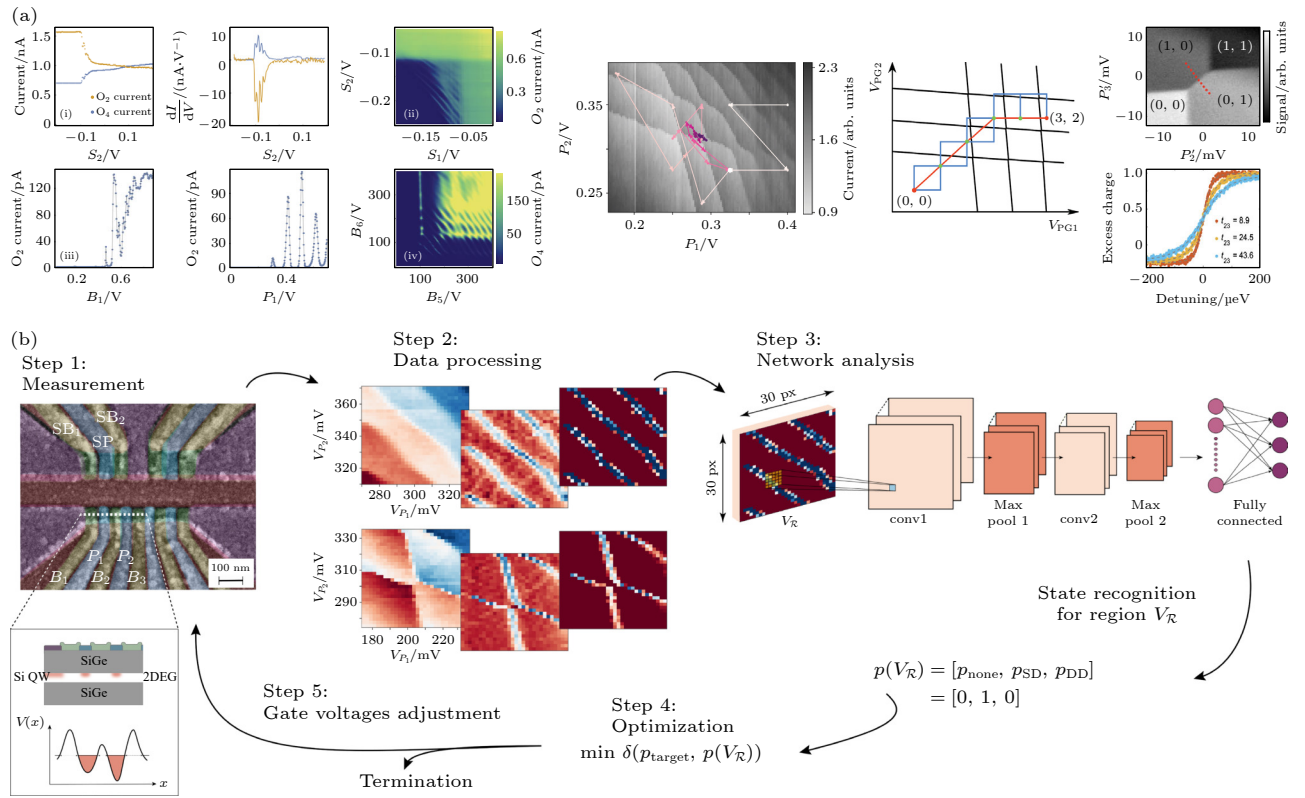
### 3.1.3 读出

读出负责将量子比特信息转化为经典信息<sup>[48]</sup>, 当前 NISQ 设备中, 读出环节是错误的主要来源之一, 其中多种人工智能应用模型 (图 8) 被提出.

超导量子比特的色散读出产生同相 (I) 和正交 (Q) 信号的时间序列, 然而自发态跃迁、读出脉

冲激发及频率复用串扰等复杂错误源, 使得简单判别器难以有效处理. 深度神经网络 (deep neural

network, DNN) 显示出作为强大非线性分类器的潜力. Lienhard 等 [49] 证明, 直接处理原始 I/Q 数



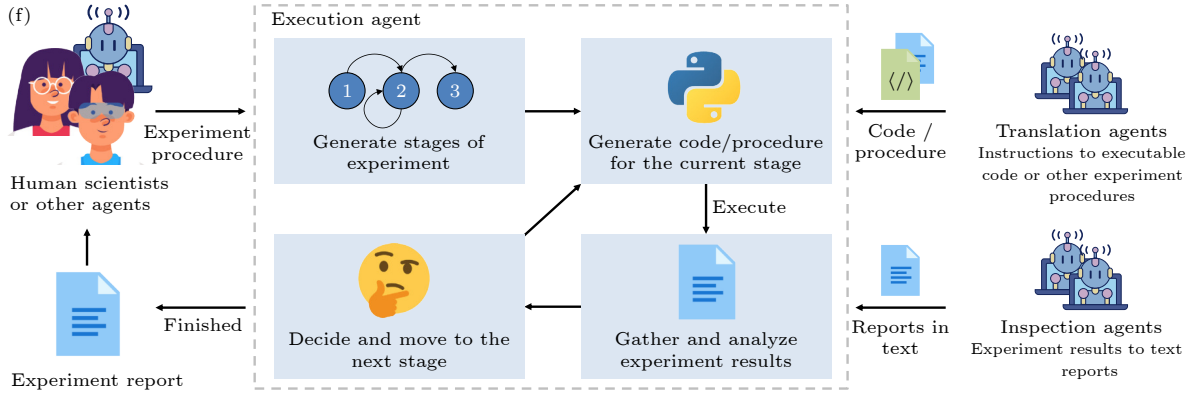


图 7 量子设备自动化校准与调谐中的机器学习模型与框架 (a) 自动化调谐流程示意图<sup>[47]</sup>; (b) 基于 CNN 的设备状态识别与粗调闭环<sup>[41]</sup>; (c) OBSID 闭环流程<sup>[43]</sup>; (d) 用于量子最优控制的强化学习框架<sup>[42]</sup>; (e) 半导体自旋量子比特全自主调谐的多阶段算法流程<sup>[45]</sup>; (f) 用于自动驾驶实验室的 k-agents 智能体框架<sup>[46]</sup>

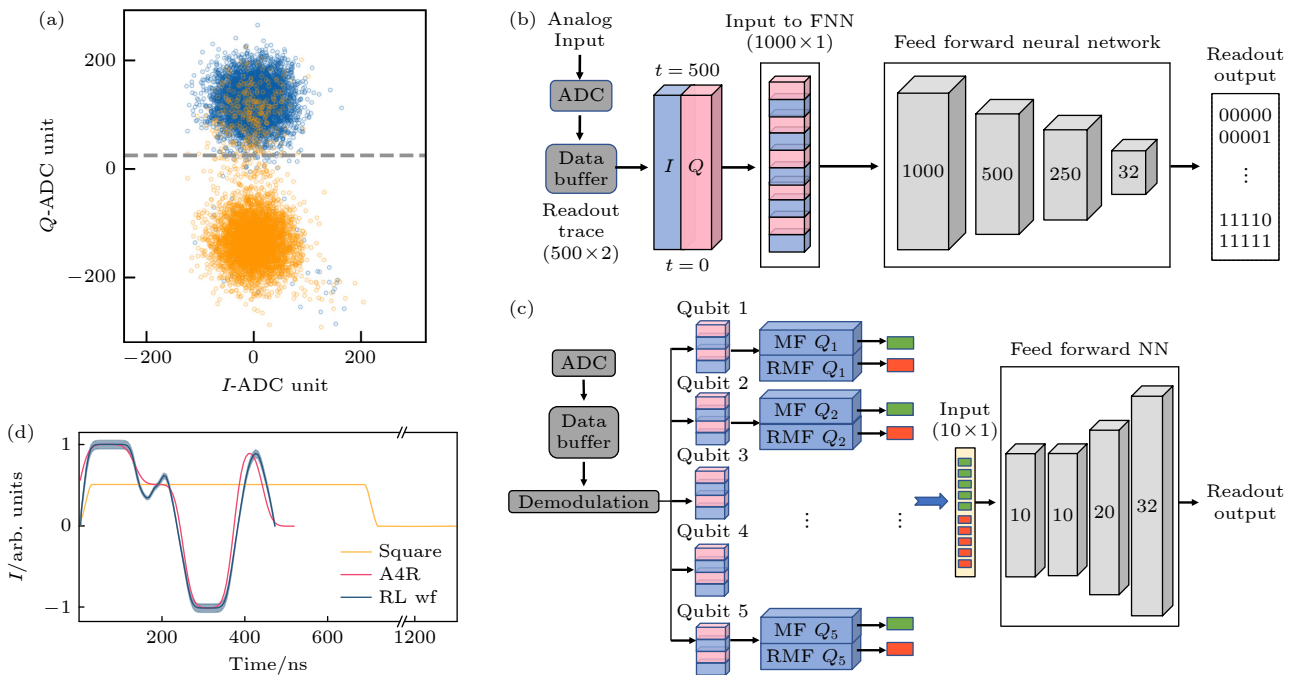
Fig. 7. Machine learning models and frameworks in the automated calibration and tuning of quantum devices: (a) Schematic workflow for automated tuning<sup>[47]</sup>; (b) CNN-based closed-loop for device state recognition and coarse tuning<sup>[41]</sup>; (c) closed-loop process for OBSID<sup>[43]</sup>; (d) reinforcement learning framework for quantum optimal control<sup>[42]</sup>; (e) multi-stage algorithm workflow for fully autonomous tuning of a semiconductor spin qubit<sup>[45]</sup>; (f) k-agents framework for self-driving laboratories<sup>[46]</sup>.

据的前馈神经网络 (feedforward neural network, FNN) 能补偿系统非理想性, 将分配错误率降低高达 25%, 串扰减少一个数量级. 除了改进信号判别, AI 还能优化读出过程本身. Chatterjee 等<sup>[50]</sup> 利用无模型的 RL 整体优化读出脉冲波形, 实现了低分配错误率, 并将读出与谐振腔重置速度提升近三倍.

然而, 大型 AI 模型在需要快速实时反馈的现场可编程门阵列 (field-programmable gate array, FPGA) 上部署面临挑战<sup>[48,51]</sup>. 为此, 硬件高效的 ML 架构应运而生. Maurya 等<sup>[48]</sup> 提出的 HERQULES

架构, 通过经典的匹配滤波器层次结构降维后输入小型神经网络, 在保持可扩展性的同时, 精度比基线 FNN 提高了 16.4%. Guglielmo 等<sup>[51]</sup> 则展示了使用 hls4 ml 等工具的端到端工作流程, 通过协同设计和量化感知训练 (quantization-aware training, QAT) 压缩模型, 在消耗不到 16% FPGA 资源的情况下, 实现了 96% 保真度和 32 ns 延迟.

此外, 机器学习还可用于测量误差的后处理校正, 即量子误差缓解的机器学习 (machine learning for quantum error mitigation, ML-QEM)<sup>[52]</sup>. Liao



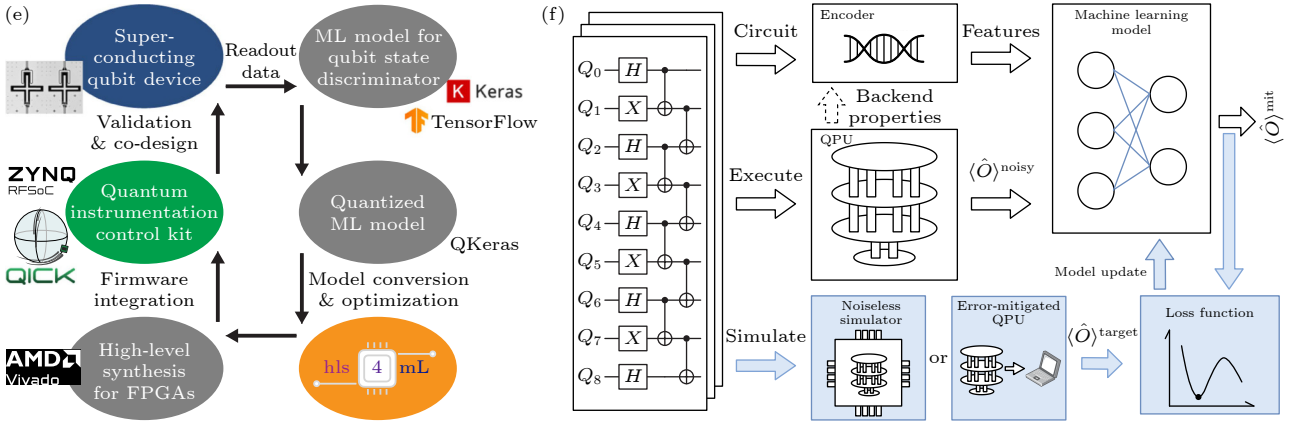


图 8 人工智能在量子读出的几种应用模型概念图 (a) 读出信号 I/Q 分布示例<sup>[51]</sup>; (b) 基线 FNN 判别器架构<sup>[48]</sup>; (c) 硬件高效 HERQULES 架构<sup>[48]</sup>; (d) RL 优化的读出脉冲波形对比<sup>[50]</sup>; (e) 端到端软硬件协同设计 workflow<sup>[51]</sup>; (f) 量子纠错 ML-QEM workflow<sup>[52]</sup>  
 Fig. 8. Conceptual diagrams of several applications of AI in quantum readout: (a) Readout signal I-Q distribution example<sup>[51]</sup>; (b) baseline FNN discriminator architecture<sup>[48]</sup>; (c) hardware-efficient HERQULES architecture<sup>[48]</sup>; (d) comparison of RL-optimized readout pulse waveforms<sup>[50]</sup>; (e) end-to-end hardware-software co-design workflow<sup>[51]</sup>; (f) ML-QEM workflow for quantum error mitigation<sup>[52]</sup>.

等<sup>[52]</sup>的研究证明, 训练随机森林或多层感知器等 ML 模型学习设备错误, 能预测校正后的无噪声值, 其精度可匹敌甚至超越标准方法, 同时将运行时开销降低两倍以上。

### 3.2 AI 用于量子纠错与缓解

执行动态算法需主动管理计算错误, 因此对抗噪声、提升计算可靠性具有重要应用。管理量子噪声现有两大范式: 一是长期高开销的量子纠错 (quantum error correction, QEC), 旨在在物理错误率低于阈值的条件下, 将逻辑错误率随码距增加而压低到目标水平; 二是近期实用的量子错误缓解 (quantum error mitigation, QEM), 通过统计后处理估算无噪声结果, 避免 QEC 的全部开销<sup>[53]</sup>。

#### 3.2.1 AI 增强量子纠错解码

QEC 通过冗余编码和综合征测量来保护量子信息并纠正错误<sup>[54]</sup>, 传统算法如最小权重完美匹配 (minimum-weight perfect matching, MWPM) 解码复杂且难以满足微秒级的实时性要求。且通常基于简化噪声模型的传统算法难以适应硬件中复杂的实际噪声<sup>[55]</sup>。此外, 许多基于硬判决综合征的传统解码器通常丢弃原始模拟信号中的不确定性信息。

如图 9 所示, AI 不依赖预设的、通常不准确的误差模型, 而是直接从数据中学习最优误差管理策略<sup>[13,56]</sup>。这种范式赋予了它卓越的适应性, 能识别

并对抗复杂误差模式<sup>[55]</sup>。通过直接学习从综合征到最可能误差的最优映射, AI 隐式地构建了比人为指定更精确复杂的噪声模型, 为真实量子计算机提供了更鲁棒的解决方案。

CNN 因能识别局部模式, 适合表面码等拓扑码。Gicev 等<sup>[57]</sup>的研究展示, 基于 CNN 的解码器可扩展至千级码距 (数百万物理比特), 且解码时间理论上与码距无关。更先进的 AI 架构, 如 Transformer, 利用注意力机制捕捉综合征中复杂的长程依赖, 对处理关联噪声很重要<sup>[58]</sup>。此外, 生成式模型, 如 Cao 等<sup>[59]</sup>研究的自回归神经网络, 能无监督学习错误与综合征的联合分布, 高效执行近似最大似然解码 (maximum likelihood decoding, MLD), 尤其适用于高码率多逻辑比特编码。Choukroun 与 Wolf<sup>[58]</sup>的工作也验证了深度学习在直接优化逻辑错误率 (logical error rate, LER) 和处理错误测量方面的能力。大量研究证实, AI 解码器在处理更真实的关联噪声时, 性能优于 MWPM, 逻辑错误率显著降低。

谷歌的 AlphaQubit 模型采用了循环-Transformer 混合架构<sup>[55]</sup>, 并利用了“软信息”(原始模拟测量信号) 获取更丰富的测量不确定性信息。通过模拟数据预训练和少量真实实验数据微调, Alpha Qubit 适应了设备的复杂误差, 解码准确率超越了包括 MWPM 和张量网络 (tensor network, TN) 解码器在内的先前方法, 有力证明了 AI 解码器的实战潜力。

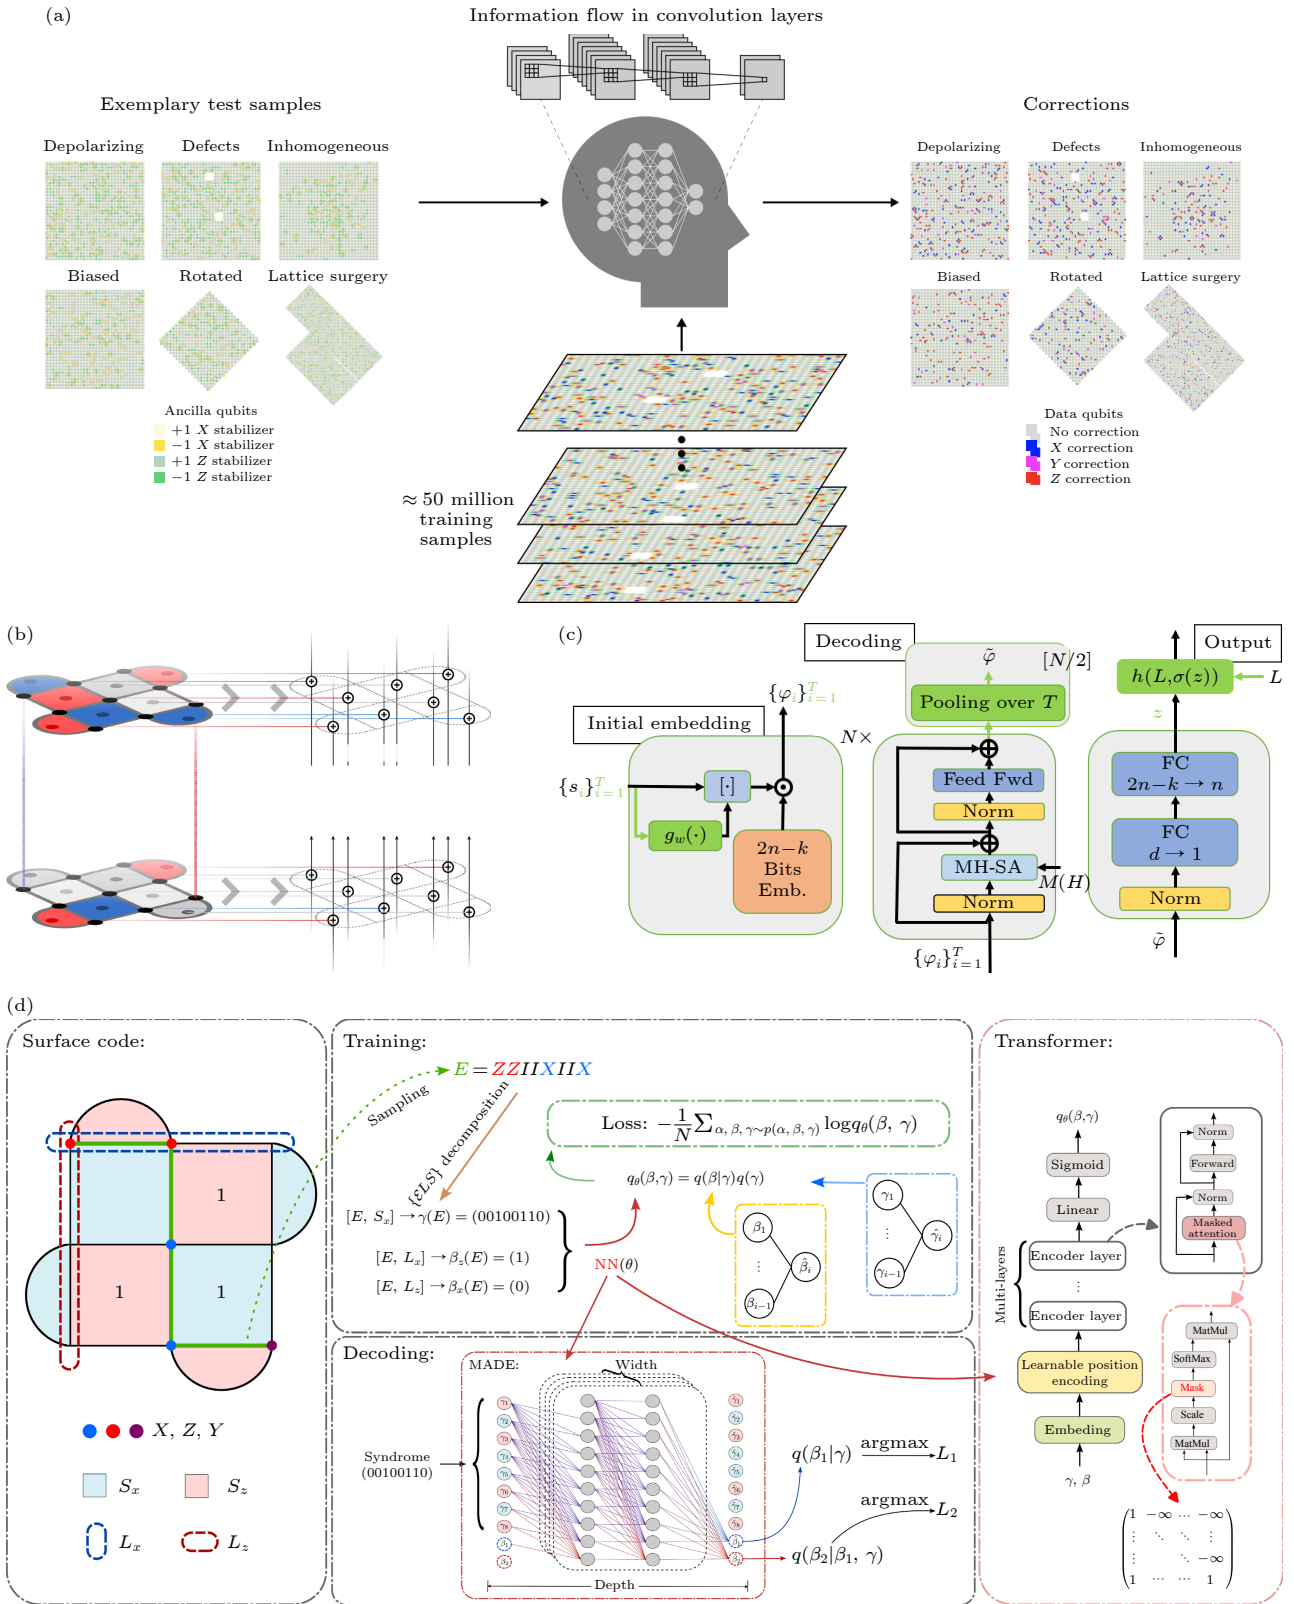


图 9 AI 增强的量子纠错解码器新范式 (a) CNN 解码器: 将综合征视为图像识别局部模式<sup>[57]</sup>; (b) 循环-Transformer 解码器: 按时序处理综合征, 捕捉时序关联<sup>[55]</sup>; (c) Transformer 解码器: 利用注意力机制捕捉长程依赖<sup>[58]</sup>; (d) 生成式自回归解码器: 顺序、条件性地生成逻辑错误<sup>[59]</sup>

Fig. 9. New paradigms of AI-enhanced quantum error correction decoders: (a) CNN decoder: Treats syndrome as image to identify local patterns<sup>[57]</sup>; (b) recurrent-Transformer decoder: Processes syndromes sequentially for temporal correlations<sup>[55]</sup>; (c) transformer decoder: Uses attention mechanism to capture long-range dependencies<sup>[58]</sup>; (d) generative autoregressive decoder: Sequentially and conditionally generates logical errors<sup>[59]</sup>.

### 3.2.2 AI 优化与发现纠错码

AI 不仅能优化解码, 还能自主发现定制化的量子纠错码 (quantum error correction code, QECC)(典型方案架构见图 10). RL 是其中一项关键技术, 在 RL 框架中, 智能体通过“玩游戏”的方式构建 QECC 以最大化奖励函数 (如码距或噪声鲁棒性). 例如, Su 等<sup>[60]</sup> 利用“量子乐高”框架, 让智能体通过张量收缩组装简单编码模块来构建大型编码. 通过优化对特定偏置噪声的鲁棒性作为奖励, 他们发现了性能超越基准的新编码, 有时这些编码码距虽低, 但因逻辑算符权重分布更优而表现更好, 挑战了以码距为核心的传统理念. 为降低测量开销, He 与 Liu<sup>[61]</sup> 利用 RL 发现了低测量权重的量子低密度奇偶校验码 (quantum Low-Density Parity-Check, qLDPC), 其智能体将物理比特开

销显著降低, 使容错计算在近期实验中更可行.

其他 AI 方法也在编码发现中起作用. 量子自编码器 (quantum autoencoders, QAEs) 作为一种量子神经网络 (quantum neural network, QNN), 能被训练来发现新逻辑编码并执行自主量子纠错 (autonomous quantum error correction, AQEC). QAE 被训练成一个量子通道, 能将含噪状态自动映射回无噪声编码空间, 无需外部测量和反馈, 并能发现最适合特定噪声的新编码<sup>[62]</sup>.

神经网络还可优化码字本身定义. Zeng 等<sup>[63]</sup> 利用神经网络对定义近似 Gottesman-Kitaev-Preskill (GKP) 玻色编码的系数函数进行建模和优化. 结果显示, 神经网络优化的 GKP 编码在纠错性能上优于传统方法, 同时所需压缩相干态数量仅为后者的三分之一, 显著地降低了物理制备的复杂性.

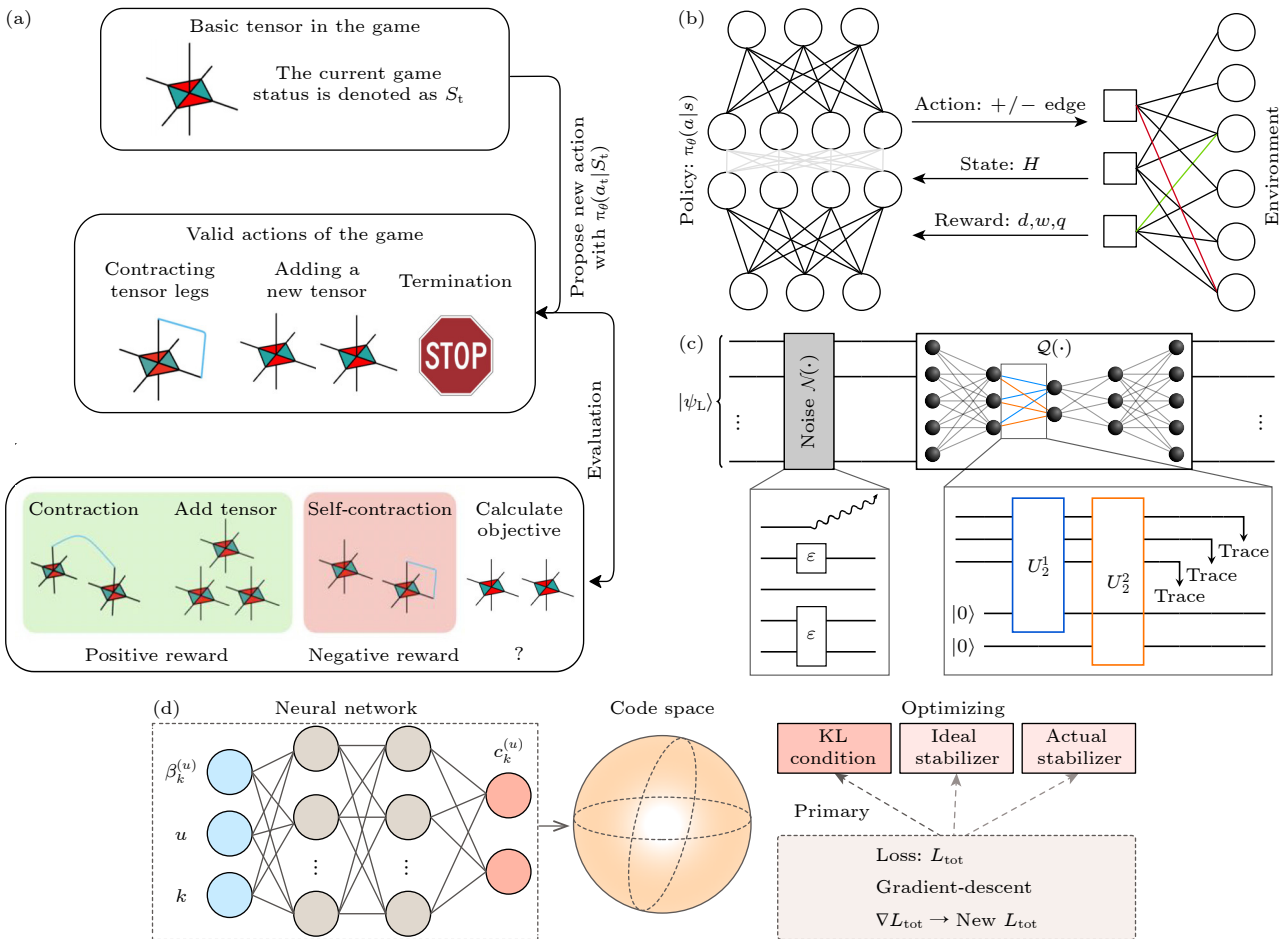


图 10 AI 在量子纠错编码发现与优化中的应用 (a) RL+量子乐高发现编码<sup>[60]</sup>; (b) RL 优化 qLDPC 权重<sup>[61]</sup>; (c) QAE 自主纠错<sup>[62]</sup>; (d) 神经网络设计 GKP 编码<sup>[63]</sup>

Fig. 10. Applications of AI in the discovery and optimization of quantum error correction codes: (a) RL + Quantum Lego for code discovery<sup>[60]</sup>; (b) RL optimizes qLDPC weights<sup>[61]</sup>; (c) QAE for autonomous QEC<sup>[62]</sup>; (d) neural networks design GKP codes<sup>[63]</sup>.

### 3.2.3 AI 用于量子误差缓解

在 NISQ 计算时代, 量子误差缓解提供了一种近期策略, 旨在减少噪声对最终期望值的影响 [64]. 传统 QEM 方法如零噪声外推 (zero-noise extrapolation, ZNE) 和概率误差消除 (probabilistic error cancellation, PEC) 存在巨大运行时开销. 机器学习 QEM (ML-QEM) 提供了解决方案. Liao 等 [52] 证明 ML 模型可学习噪声映射. 其 workflow 是训练模型 (如被证明性能稳健的随机森林 (random forest, RF)) 来预测无噪声结果, 在随机电路基准测试中, RF 的平均误差低于 ZNE、普通最小二乘法 (ordinary least squares, OLS)、多层感知器 (multi-layer perceptron, MLP) 和图神经网络 (graph neural network, GNN). 对于经典不可解的大电路, Liao 等提出训练模型模仿 ZNE 等传统方法的结果, 在 100 量子比特的电路上, 能以 50% 的运行时开销达到相似精度.

为改进噪声表征, Zheng 等 [65] 使用贝叶斯推断将错误率视为具有后验分布的随机变量, 而非固定值. 这种方法构建的滤波器能有效校正结果, 在 Grover 搜索和深电路测试中均优于标准技术. 为解决通用 ML 模型的黑箱和数据依赖问题, Xu 等 [64] 提出了物理启发的神经噪声累积代理 (neural

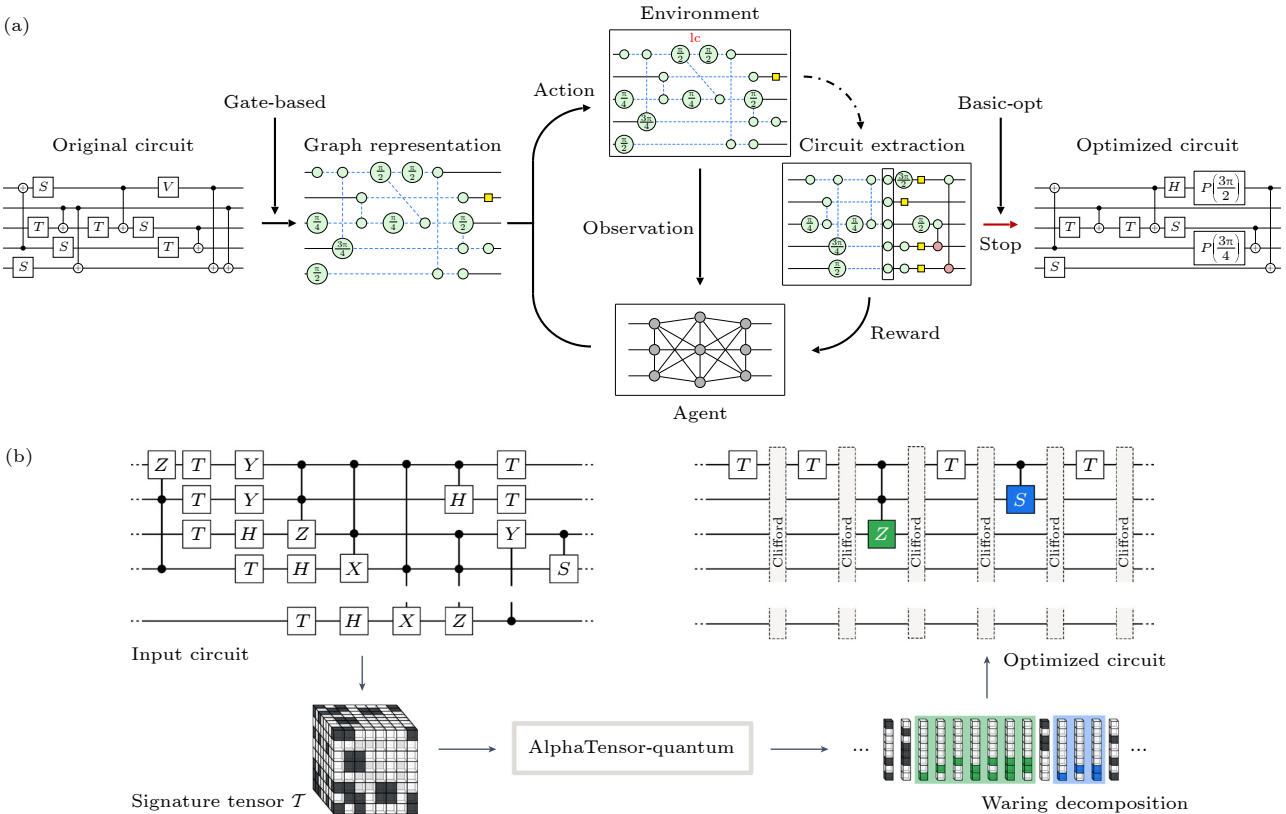
noise accumulation surrogate, NNAS). NNAS 的架构包含一个循环结构以模拟噪声逐层累积的递归物理过程, 其内部状态与累积噪声在结构上保持一致. 该灰箱模型在量子近似优化算法电路上的平均绝对误差更低, 所需训练数据减少一个数量级, 并在 ZNE 等失效的深层电路中将误差减半.

### 3.3 AI 用于量子电路优化与设计

如何从硬件提供的基础操作出发, 设计出高效、鲁棒且符合物理约束的量子电路? 其本质是在一个随量子比特和操作数指数增长的、高度非直观的空间中搜索最优门序列. 传统启发式方法易陷入局部最优, 量子纠错编码带来的严格物理约束也使问题复杂.

#### 3.3.1 AI 驱动量子编译

量子编译负责将抽象量子算法转化为特定量子处理单元 (quantum processing unit, QPU) 上的可执行门序列. 由于 QPU 存在物理限制, 编译不仅是翻译, 更是复杂的优化任务, 涉及逻辑到物理量子比特的映射及插入额外操作 (如 SWAP 门) 以克服限制, 同时最小化噪声与开销. 核心挑战可分为两个层面: 硬件无关的逻辑简化和硬件感知的物理映射. 典型编译与控制流程见图 11.



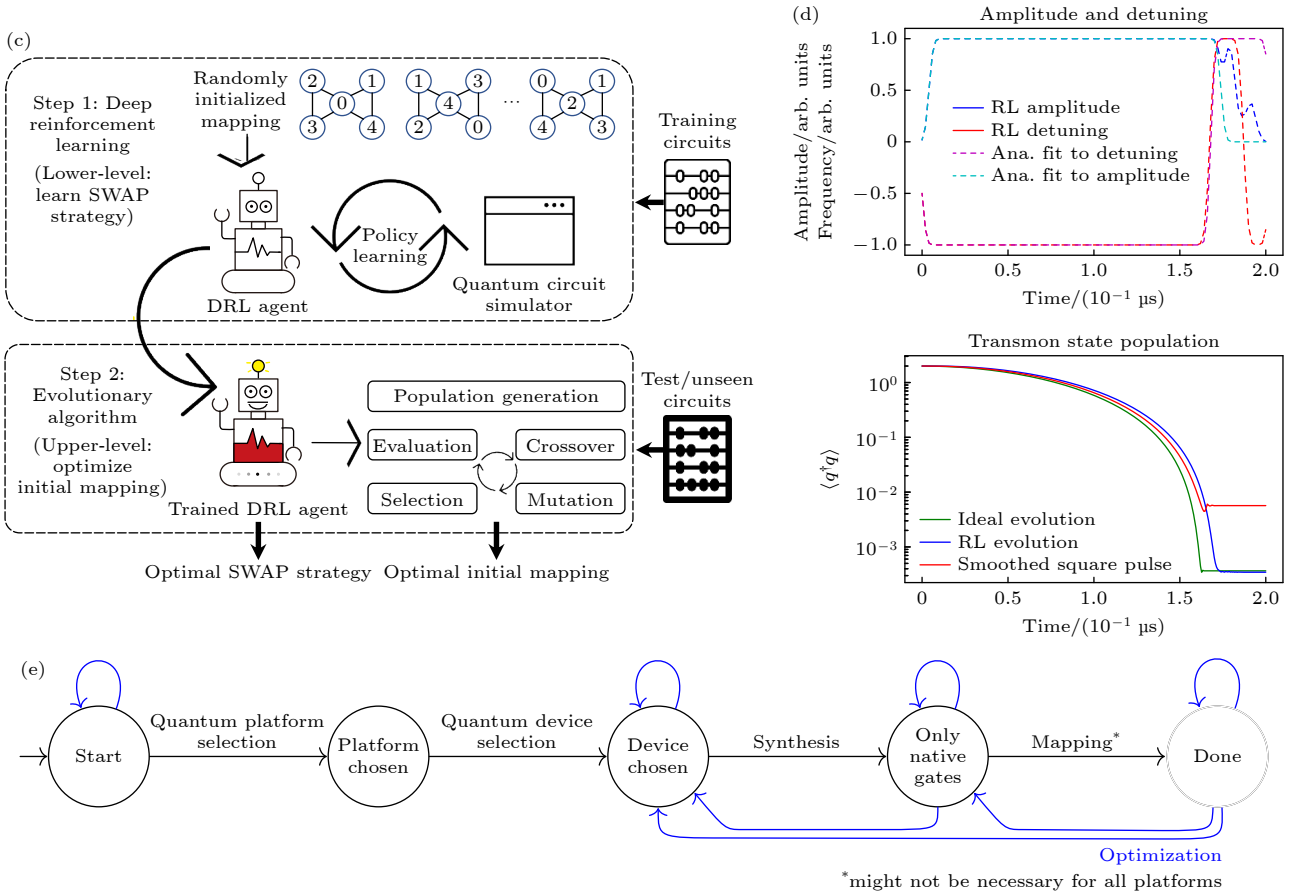


图 11 人工智能在量子计算编译和控制中的应用 (a) 基于 RL 和 ZX-calculus 的量子线路优化流程<sup>[66]</sup>; (b) AlphaTensor-Quantum 的量子线路优化流程<sup>[67]</sup>; (c) 用于量子线路布局的双层机器学习优化框架<sup>[68]</sup>; (d) AI 在 Transmon 比特复位控制中取得的新成果<sup>[69]</sup>; (e) 将量子编译流程建模为马尔可夫决策过程<sup>[70]</sup>

Fig. 11. Applications of AI in quantum computing compilation and control: (a) The quantum circuit optimization workflow based on RL and ZX-calculus<sup>[66]</sup>; (b) the quantum circuit optimization workflow of AlphaTensor-Quantum<sup>[67]</sup>; (c) a two-level machine learning-based framework for quantum circuit placement<sup>[68]</sup>; (d) a novel achievement of AI in transmon qubit reset control<sup>[69]</sup>; (e) modeling the quantum compilation flow as a Markov decision process<sup>[70]</sup>.

在硬件无关层面, 优化旨在减少门数和电路深度而不改变逻辑功能. 这相当于在巨大的状态空间中搜索最优电路变换. RL 代理擅长学习此类复杂环境中的策略. 通过将电路表示为图, 并用 GNN 提取特征, RL 代理能学到优于启发式规则的简化策略. 一个成功的理论框架是 ZX-calculus, 它提供一种纯图形化语言来表示和推理量子过程. 研究表明, RL 代理能智能地应用 ZX-calculus 重写规则有效压缩电路, 且能力可从小型电路训练泛化到大型电路上<sup>[66]</sup>. 在容错计算领域, 最小化 T 门数量至关重要. Ruiz 等<sup>[67]</sup>开发的 AlphaTensor-Quantum 将此问题转化为张量分解, 利用深度 RL 寻找低秩分解, 对应更少 T 门的电路. 该方法在基准测试中超越已知算法, 显著降低 T 门数量, 并独立发现了类 Karatsuba 快速乘法的量子算法.

逻辑简化后需将电路映射到特定 QPU 拓扑. 有限连接性常需插入 SWAP 门, 但这会增加错误和深度. 寻找最优映射与 SWAP 策略是 NP 完全问题. 针对这一难题, Fan 等<sup>[68]</sup>提出双层优化框架应对此挑战: 上层用演化算法 (evolutionary algorithm, EA) 搜索初始布局, 下层部署深度强化学习 (deep reinforcement learning, DRL) 代理学习最优 SWAP 策略. 与领先的启发式方法相比, 可大幅减少甚至消除 SWAP 门开销, 且在保持与精确算法同等优化水平下, 运行时间缩短了 40 倍.

AI 也可优化实现量子门的物理控制信号. Ernst 等<sup>[69]</sup>开发了物理约束 RL 算法, 通过引入演化速率硬约束和脉冲平滑度软约束, 生成了符合硬件限制、高保真且对噪声鲁棒的控制脉冲, 发现了新的 transmon 比特复位方案.

这些研究进展预示着未来“学习型编译器堆栈”的出现. 经典编译器通常包含多轮优化遍, 当前 AI 已在特定编译任务 (如 T 门优化、路由) 中表现出色. Quetschlich 等 [70] 提出用 RL 学习为特定电路和硬件寻找优化遍的最佳组合顺序. 未来的量子编译器或由一组协同工作的专用 AI 代理构成, 分别负责逻辑简化、硬件映射等. 这种模块化编译器将极具适应性, 面对新 QPU 架构, 通过重新训练即可自动生成优化策略, 改变当前手动开发的模式.

### 3.3.2 算法与变分电路的自动化设计

变分量子算法 (variational quantum algorithms, VQA) 是 NISQ 时代最有希望展示量子优势的

的算法之一 [71], 采用经典与量子协同工作的模式, 利用经典优化器来迭代训练参数化的量子线路 (ansatz) 以最小化目标函数. 其中 Ansatz 的选择必须平衡“表现力”(覆盖解空间) 和噪声鲁棒性, 这催生了量子架构搜索 (quantum architecture search, QAS) 这一 AI 的理想应用领域 [72]. 不同搜索范式见图 12.

强化学习再次显示了其应用潜力. RL 代理被训练来执行一个序列决策过程: 从空线路开始, 逐步选择门添加到线路中. 线路的最终性能 (如能量精度) 被转化为奖励信号反馈给代理. Ostaszewski 等 [72] 展示了算法能够自主探索用于计算氢化锂 (LiH) 分子基态能量的量子线路结构的 RL 算法.

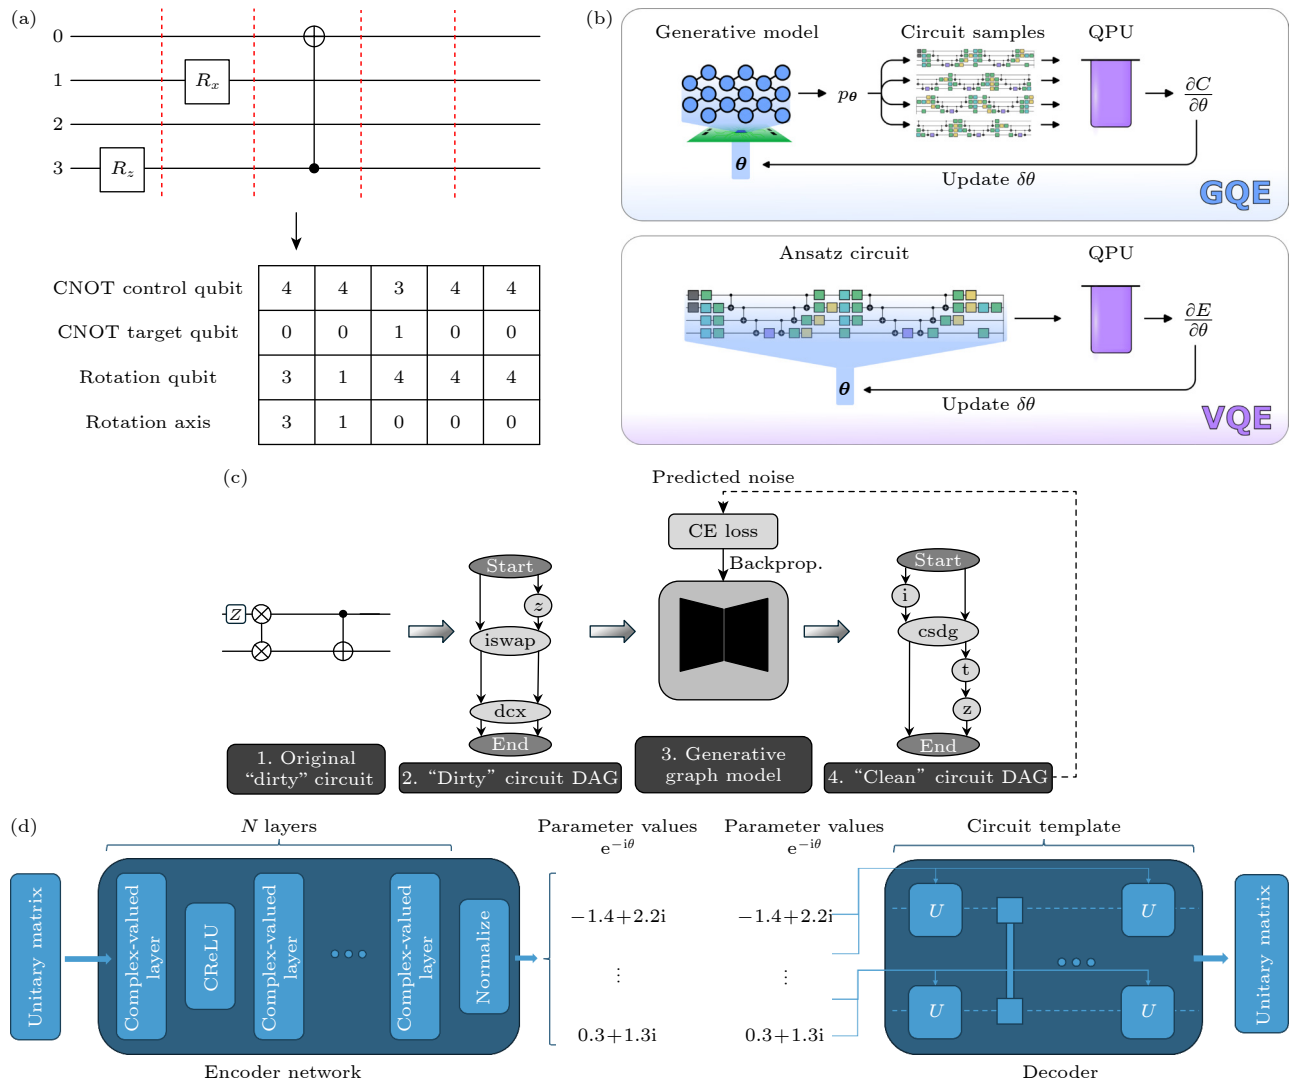


图 12 AI 在量子架构搜索中的不同范式 (a) RL 的状态表示与逐步电路构建 [72]; (b) GQE 与 VQE 对比: GQE 的优化在经典模型 [74]; (c) 扩散模型通过“去噪” DAG 图生成电路 [73]; (d) 用于参数预测的自编码器网络结构 [75].

Fig. 12. Different paradigms of AI in quantum architecture search: (a) RL state representation and sequential circuit building [72]; (b) GQE vs. VQE: GQE's optimization is in the classical model [74]; (c) diffusion model generating circuits by "denoising" DAGs [73]; (d) autoencoder network structure for parameter prediction [75].

与 RL 的逐步构建不同, 生成式 AI (generative AI) 提供了“一次性生成”范式. 学习有效电路的数据分布, 然后从中直接采样, 生成全新的电路实例. 其中, 扩散模型已被成功应用于此<sup>[73]</sup>. 该方法将电路表示为有向无环图 (directed acyclic graphs, DAGs), 通过“去噪”过程从随机图逐步恢复出合法的量子电路, 实验展示了生成 100% 有效电路的能力. 其他生成式架构也显示出巨大潜力, 如基于 Transformer 模型的生成式量子本征求解器 (generative quantum eigensolver, GQE) 被用于自动生成计算分子基态的量子电路<sup>[74]</sup>. 它将优化的核心从量子线路转移到了经典的生成模型上, 训练 Transformer 直接“书写”出无参数的量子电路“文档”, 使其大概率产生低能量值. 该方法在计算氮气分子 ( $N_2$ ) 时展示了超越经典耦合簇单双激发方法的潜力, 且支持预训练以加速新问题的求解.

除了直接生成电路, 机器学习也被用于解决 QAS 中的特定子任务. Kremer 等<sup>[75]</sup> 提出了一种混合流程: 该流程利用监督学习模型进行“模板选择”, 然后, 利用一个创新的、类似自编码器的模型进行“参数预测”, 解码器被设计为可微分的量子电路模拟器本身, 这使得编码器可以直接以最大化重构保真度为目标进行端到端的训练, 从而为后续的梯度优化提供一个极佳的初始参数点, 显著加速了编译过程.

### 3.4 AI 用于量子信息处理

在 3.1 节—3.3 节中, 探讨了人工智能在量子硬件层面的应用, 如设备校准、操控优化及纠错解码. 随着研究的深入, 利用 AI 解决量子信息科学中的核心理论难题同样值得关注, 本节将综述近年来利用 AI 在量子纠缠探测、非定域性验证及量子态层析等方面取得的突破性进展. 具体典型应用范式可见图 13.

量子纠缠是量子信息处理的核心资源, 但在实验上判定一个未知多体态是否纠缠通常被认为是 NP-hard 难题. 传统的线性纠缠目击者 (entanglement witness, EW) 方法虽然通用, 但在面对实验噪声或特定混合态时往往缺乏鲁棒性. 针对这一挑战, AI 引入了非线性分类边界, 极大地提升了探测的灵敏度与泛化能力. Roik 等<sup>[76]</sup> 提出了一种基于人工神经网络的非线性纠缠探测框架. 相比于线性目击者, 神经网络能够在希尔伯特空间中构建非线性

性的分类边界. 这种能力使得 AI 在仅利用部分测量信息的情况下, 依然能以极高的精度区分纠缠态与可分态. 该方法有效地克服了传统纠缠目击者在检测混合态时普遍存在的严重“假阴性” (第二类错误) 问题, 并已成功在真实的实验数据集中得到验证.

贝尔非定域性是量子力学最深刻的特征之一. 对于多体系统, 寻找最优贝尔不等式以验证非定域性是一个极具挑战的优化问题. AI, 特别是强化学习, 在此领域展现了超越人类直觉的发现能力. Deng<sup>[77]</sup> 提出利用受限玻尔兹曼机表示量子态, 通过强化学习优化网络参数, 以寻找能够最大程度违背给定贝尔不等式的多体量子态. 该工作验证了神经网络在处理高维量子多体非定域性问题上的强大能力, 不仅在短程关联系统中复现了高精度结果, 更在传统方法难以处理的全连接关联系统中展现了独特优势, 这表明利用 AI 自主设计全新的贝尔不等式将是该领域未来的重要研究方向. 进一步地, Canabarro 等<sup>[78]</sup> 训练多层感知机来区分经典、量子 and 超量子关联, 成功地描绘了“量子集”的几何边界. 这表明机器学习模型能够隐式地构建高维量子关联集合的几何模型. 在实验设计方面, Krenn 等<sup>[79]</sup> 开发的“PyTheus”框架利用图论和 AI 自动设计复杂的量子光学实验, 该系统已自动发现了多个实验配置.

量子态层析是从不完备或含噪的测量数据中重构量子系统密度矩阵  $\rho$  的核心任务. 传统最大似然估计方法在处理大规模系统时面临计算复杂度呈指数级增长的瓶颈. 近年来, 基于神经网络量子态和深度生成模型的方法, 通过将量子态编码为神经网络参数, 成功突破了这一限制. 在该领域的开创性工作中, Torlai 等<sup>[80]</sup> 首次证明了受限玻尔兹曼机能够高效学习并重构高度纠缠的多体量子态. Carrasquilla 等<sup>[81]</sup> 将这一框架扩展至混合态, 提出了基于正算符值测量结果的生成模型, 将层析转化为无监督学习问题. 该方法不仅能处理混合度未知的量子态, 还能内禀地保证密度矩阵满足半正定性等物理约束, 展示了在稀疏数据下的强泛化能力. 随后, 为了提升重构效率, Ahmed 等<sup>[82]</sup> 引入了条件生成对抗网络, 通过引入自定义层确保物理约束, 不仅显著减少了对测量数据的需求, 更通过预训练实现了“单次评估”的快速层析能力. 针对量子态中复杂的纠缠结构, Cha 等<sup>[83]</sup> 提出了基于注意

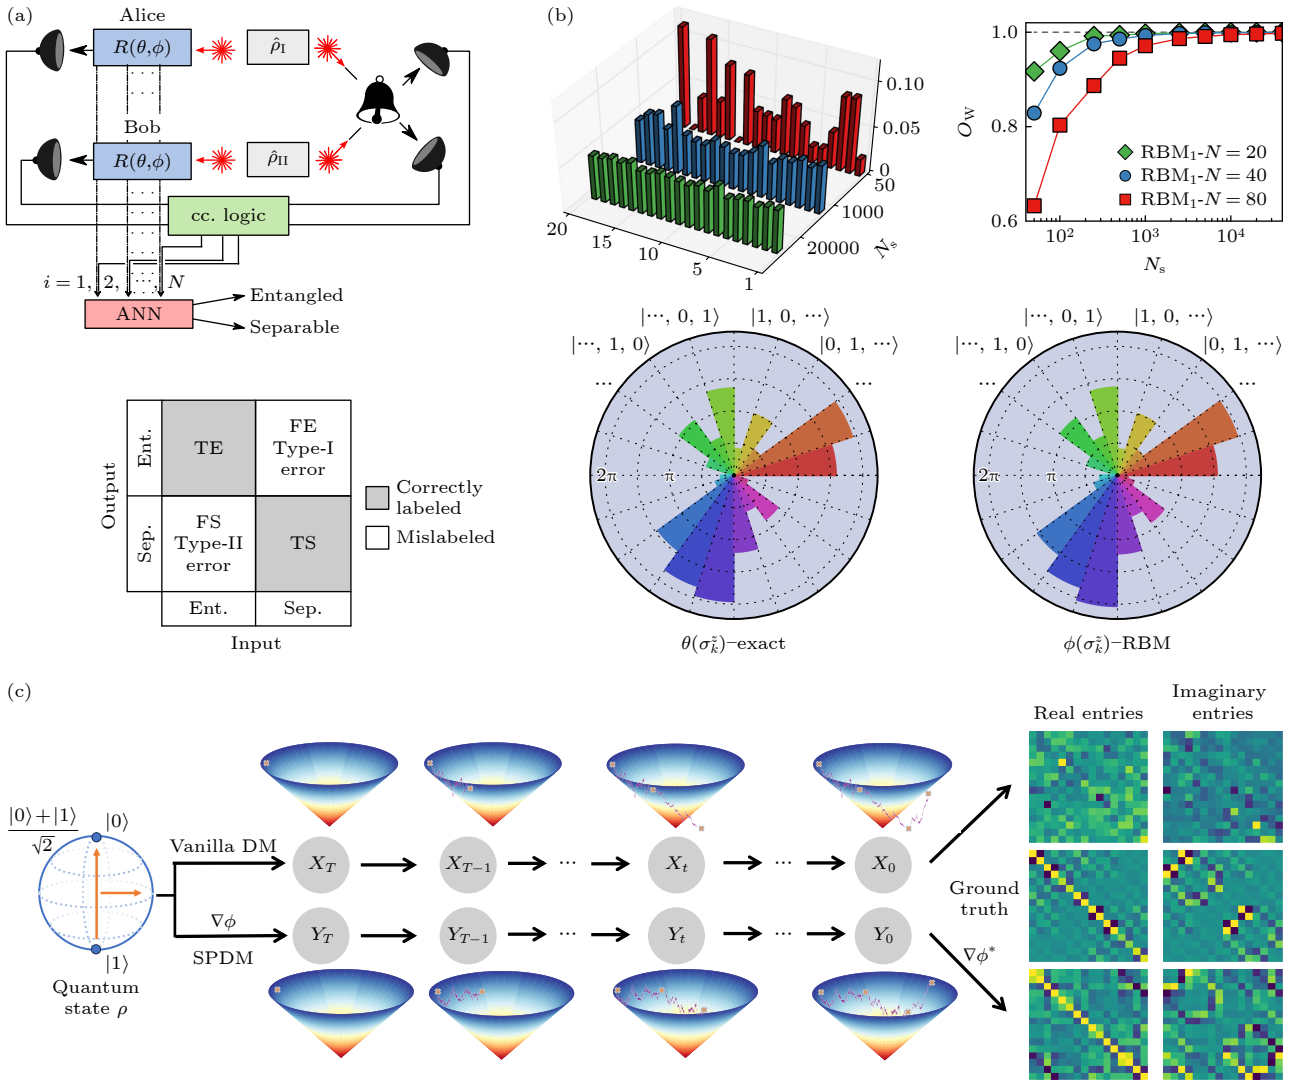


图 13 AI在量子信息处理中的典型应用范式 (a) 基于神经网络的纠缠探测方案<sup>[76]</sup>; (b) 神经网络量子态层析基准测试<sup>[80]</sup>; (c) 结构保持扩散模型示意图<sup>[85]</sup>  
 Fig. 13. Typical paradigms of AI in quantum information processing. (a) Scheme of ANN-based entanglement detection<sup>[76]</sup>; (b) benchmarking neural-network quantum state tomography<sup>[80]</sup>; (c) structure-preserving diffusion model schematic<sup>[85]</sup>.

力机制的量子层析模型 (attention-based quantum tomography, AQT). 与受限于短程记忆的循环神经网络不同, AQT 利用自注意力机制有效捕捉了量子比特间的非局域长程关联, 并在含噪实验数据上展现了卓越的鲁棒性. 此外, 针对连续变量系统, Tiunov 等<sup>[84]</sup> 亦利用深度学习解决了高维光量子态的重构难题. 值得注意的是, 随着生成模型的发展, 研究焦点已延伸至量子态的生成与设计. Zhu 等<sup>[85]</sup> 近期提出了结构保持扩散模型, 该工作虽然与层析相关, 但其核心目标是学习混合态的分布并生成新的合规量子态. 该模型利用凸优化中的镜像映射技术, 在对偶空间进行扩散过程, 从而解决了传统生成模型难以严格满足密度矩阵半正定性等

物理约束的难题.

### 3.5 小结

本节深入探讨了“AI for Quantum”, 阐述 AI 如何赋能量子计算, 克服 NISQ 时代硬件挑战. AI 的模式识别与优化能力正解决量子计算物理实现层面的瓶颈: 在设备表征、校准与读出层面, AI 实现了高效自动化控制与精准建模; 在量子纠错与缓解层面, AI 驱动的策略展现了超越传统算法的性能和适应性; 在量子电路优化与设计层面, AI 在巨大组合空间中发现了超越人类直觉的高效解决方案.

然而, 在显著的进展之下, 现阶段研究仍需跨越几大严峻挑战. 首当其冲的是模型可解释性与物

理一致性的缺失. 当下的 AI 系统常被视为“黑盒”, 其产出的优化策略缺乏物理层面的可解释性. 建立对 AI 驱动量子编译器的信任, 关键在于发展可解释人工智能, 不仅要 AI 发现的策略转化为可理解的物理规则, 更需建立针对 AI 生成电路的形式化验证方法. 其次, 面对真实量子系统中动态漂移的噪声环境, 离线训练的静态模型往往难以持续适配. 未来的系统必须具备“在线进化”的能力, 即在量子计算机运行中实时监测环境涨落并自主调整策略, 以实现全生命周期的鲁棒控制. 最后, 实时性与延迟是 AI 赋能量子纠错面临的一大问题. 现有高精度神经网络解码器不仅推理延迟远超量子纠错周期, 且计算负荷沉重, 难以适配边缘控制硬件. 打破这一壁垒的关键, 在于推动 AI 模型的边缘端迁移, 并致力于研发软硬协同的专用神经形态硬件与轻量化模型.

综上所述, AI 不仅是提升现有硬件性能的工具, 更是构建未来大规模容错量子计算机的基石.

## 4 Quantum for AI

本节转向“Quantum for AI”, 探讨如何利用量子计算应对经典 AI 的计算瓶颈<sup>[14]</sup>. 在 NISQ 时代, 主流采用混合量子-经典框架, QPU 作为协处理器处理困难子任务. 研究主要集中于核心子领域量子机器学习 (quantum machine learning, QML), 包括 QNN 及变分量子优化. 此外, 量子计算也应用于解决 AI 中的确定性问题, 如量子规划与 NP 难组合优化. 前沿探索还涉及量子计算机视觉、量子自然语言处理和量子多智能体系统, 展现了 QAI 领域的广阔潜力.

### 4.1 量子机器学习

量子机器学习旨在利用量子计算革新机器学习范式. 经典 ML(监督学习、无监督学习及强化学习) 的核心是处理高维数据, 但在算力和内存上面面临“维度灾难”. QML 借助量子力学重塑信息处理的方式, 在一个维度呈指数级增长 ( $2^n$ ) 的希尔伯特空间中编码和处理高维数据, 建立量子优势. 通过将编码高维数据, 利用量子计算机在希尔伯特空间中进行并行线性代数运算, 有望在特定机器学习任务上实现超越经典算法的性能.

QML 领域的早期研究主要聚焦于为容错量子计算机设计的算法 (核心概念示意图图 14). 许多经典机器学习方法, 其核心计算瓶颈最终都归结为大规模线性代数运算, 例如矩阵求逆、特征值分解和内积计算<sup>[14]</sup>. 其中, 由 Harrow 等<sup>[86]</sup> 提出的 HHL 算法是里程碑. 它求解线性方程组  $Ax = b$ , 在理想条件下, HHL 的运行时间复杂度为  $\tilde{O}(\log(N) s^2 k^2 / \epsilon)$ . 这与经典算法 (如高斯消元法的  $O(N^3)$  或共轭梯度法  $O(Ns\sqrt{k} \log(1/\epsilon))$ ) 的相比, 实现了指数级的加速. 但 HHL 的局限在于: 要求矩阵  $A$  是稀疏 (或低秩)、性能受条件数  $k$  影响、输入  $b$  需能被高效制备成量子态  $|b\rangle$ ; 输出为量子态  $|x\rangle$  并非一个可直接读取的经典向量  $x$ . 因此, 它仅适用于计算解的某个全局特性, 例如计算可观测量  $M$  在解向量上的期望值  $\langle x|M|x\rangle$ .

基于 HHL, Rebentrost 等<sup>[87]</sup> 于 2014 年提出了量子支持向量机 (quantum support vector machine, QSVM). 传统支持向量机 (SVM) 涉及求解二次规划问题, 而 QSVM 采用“最小二乘 SVM”表述, 将训练任务转化为求解一个  $(M+1) \times (M+1)$  维线性方程组. 利用 HHL 求解, QSVM 理论上能

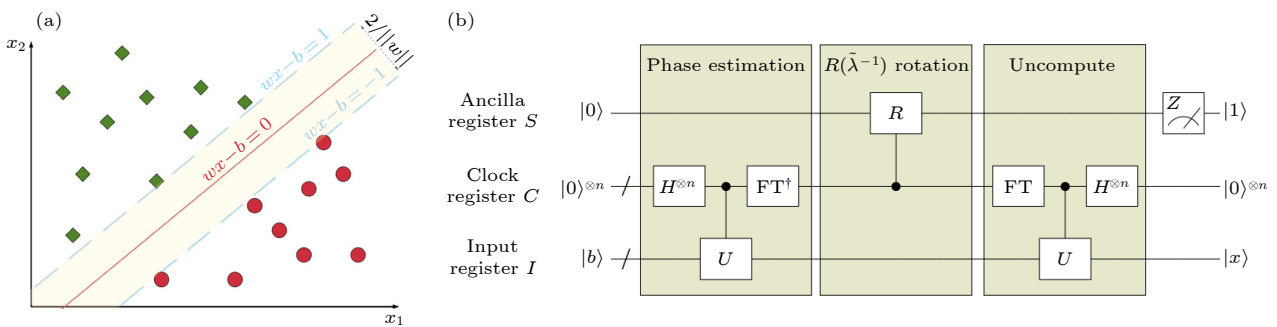


图 14 早期量子机器学习算法核心概念示意图 (a) 支持向量机的最大间隔分类原理<sup>[90]</sup>; (b) HHL 算法框架<sup>[90]</sup>

Fig. 14. Conceptual diagrams of early quantum machine learning algorithms: (a) The maximum margin classification principle of a Support Vector Machine<sup>[90]</sup>; (b) framework of the HHL algorithm<sup>[90]</sup>.

将样本数量  $M$  和特征维度  $N$  的复杂度, 从经典多项式级别 (例如  $O(\text{poly}(N, M))$ ) 降到对数级别  $O(\log(NM))$ .

除了追求计算时间上的指数加速外, 量子计算在提升数据利用效率方面同样展现出巨大潜力. 在学习理论的基础基准——优惠券收集者问题 (coupon collector problem) 中, 经典算法需要  $O(n \log n)$  次采样才能学习完备集合. Zhou 等<sup>[88]</sup> 提出并实验演示了一种基于相干态和线性光学的量子优惠券收集者协议. 该研究通过实验证实, 利用量子力学的叠加与干涉特性, 可以将样本复杂度显著降低至线性级别  $O(n)$ , 并不仅限于纯理论推导.

然而, 量子机器学习的潜力不仅仅局限于加速线性代数运算. 在探索 QML 的理论边界时, Gao 等<sup>[89]</sup> 的工作为量子生成模型 (quantum generative models, QGM) 奠定了坚实的理论基础. 不同于基于 HHL 的判别式路径, 他们提出了一种基于多体纠缠态概率幅参数化的生成模型架构, 利用张量网络结构捕捉数据中的复杂关联. 该研究在理论上严

格证明了, QGM 在表达概率分布的能力上相对于经典生成模型具有指数级的分离. 更重要的是, 对于特定的学习与推理任务, 该模型展示了在标准复杂性假设下的指数级算法加速.

HHL, QSVM 和 QGM 展示了在 ML 任务中实现指数级量子加速的理论可能, 但它们依赖容错量子硬件. 在 NISQ 时代, 实践转向了以变分子量子算法 (variational quantum algorithm, VQA) 和 QNN 为核心的混合量子-经典框架.

#### 4.1.1 变分子量子算法

变分子量子算法采用混合量子-经典计算模式 (基本流程与硬件架构见图 15): 首先, 问题被编码成代价函数  $C(\theta)$ , 其最小值是解. 同时经典优化器提供初始参数  $\theta$ , 量子处理器 (QPU) 据此配置参数化的量子线路 (parameterized quantum circuit, PQC)(也称为 Ansatz). QPU 执行该线路制备出试探量子态  $|\psi(\theta)\rangle$  并测量其上可观测量 (通常是哈密顿量  $H$ ) 的期望值, 即  $C(\theta) = \langle \psi(\theta) | H | \psi(\theta) \rangle$ . 该值反馈给经典优化器更新参数. 此循环不断重复直至收敛, 最终  $C(\theta^*)$  即为解的近似值<sup>[71]</sup>.

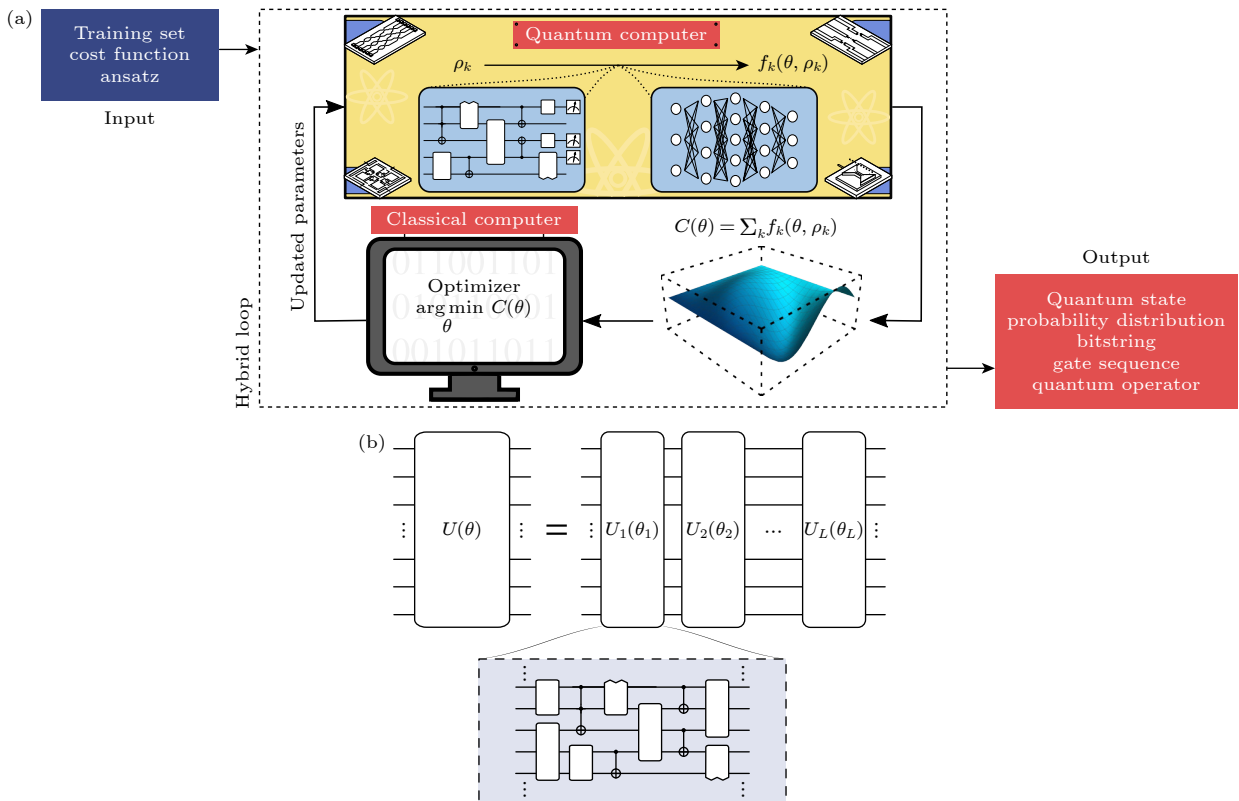


图 15 VQA 流程及 Ansatz 结构 (a) VQA 混合计算框架<sup>[71]</sup>; (b) Ansatz 的分层结构<sup>[71]</sup>

Fig. 15. The workflow of VQA and the structure of Ansatz: (a) Schematic diagram of the hybrid quantum-classical framework of VQA<sup>[71]</sup>; (b) schematic of the layered structure of an Ansatz<sup>[71]</sup>.

此范式的开创性工作是 Peruzzo 等<sup>[91]</sup>提出的变分量子本征求解器 (variational quantum eigensolver, VQE), 用于计算分子基态能量. VQE 利用变分原理: 任意试探态的能量期望值  $\langle \psi(\theta) | H | \psi(\theta) \rangle$  恒  $\geq$  基态能量  $E_G$ . 因此最小化该期望值即可近似  $E_G$ . 相较于需长相干时间的量子相位估计算法 (quantum phase estimation, QPE), VQE 将问题转化为优化任务, 极大地降低了对硬件的相干性要求, 适用于 NISQ 设备.

在这一范式下发展了电路中心型量子分类器 (circuit-centric quantum classifiers), 它直接将 PQC 作为机器学习模型<sup>[92]</sup>, 解决分类等监督学习任务. 其流程分三步:

1) 数据编码: 将经典数据  $x$  编码到量子态  $|\psi(x)\rangle$  中. 编码策略影响性能, 常用策略包括基态编码、高压缩率的振幅编码和易于在 NISQ 设备实现的角度编码. 数据编码本身就是量子优势的潜在来源. 如 Havlíček 等所示<sup>[93]</sup>, 该过程可视为计算一个强大的核函数. 量子态之间的内积  $K(x_i, x_j) = |\langle \psi(x_i) | \psi(x_j) \rangle|^2$  定义了一个量子核. 如果这个量子核经典不可高效计算, 则可能实现“量子核方法”优势.

2) 模型处理: 可训练的 PQC 处理数据, 其核心是幺正变换  $U(\theta)$ . 其中的旋转角度等参数  $\theta$  是可以被经典优化器训练的. 该线路作用于:  $|\psi_{\text{out}}\rangle = U(\theta) |\psi(x)\rangle$ .

3) 测量与预测: 测量输出态以推断标签. Mitarai 等<sup>[94]</sup>证明 PQC 具备通用函数逼近器 (universal function approximator) 的能力, 功能上等价于神经网络. 其关键在于 PQC 能利用量子系统的张量积结构和纠缠, 自动构造输入特征的高阶多项式, 从而拟合复杂的非线性函数.

#### 4.1.2 量子神经网络

QNN 是量子机器学习的核心模型架构 (关键概念与典型变体见图 16), 由量子比特替代经典神经元. 当前 NISQ 时代, VQA 是最主流实用的训练范式. 该领域的核心是设计可在 NISQ 设备上运行的 QNN 架构, 并克服贫瘠高原等可训练性挑战. 对试图模拟经典神经网络层级结构的 QNN, 其核心挑战是实现非线性激活. Beer 等<sup>[95]</sup>将感知器定义为任意酉算符, 奠定了通用计算的基础. 为克服量子力学的线性限制, 研究者利用测量引入非线性<sup>[96,97]</sup>, 或如 Gili 等<sup>[98]</sup>提出的量子神经元玻恩机,

使用带中间测量的“重复直到成功”电路.

架构设计上, Cong 等<sup>[96]</sup>提出的量子卷积神经网络 (quantum convolutional neural network, QCNN) 关联了多尺度纠缠重整化拟设 (multiscale entanglement renormalization ansatz, MERA), 在物理问题上仅需  $O(\log N)$  个参数. Beer 等<sup>[95]</sup>提出的耗散量子神经网络 (dissipative quantum neural networks, DQNN) 通过每层丢弃量子比特来解决深度网络的内存瓶颈, 其核心特征是在每层计算后“丢弃”前一层的量子比特, 使得训练所需的量子比特总数仅与网络的宽度而非深度相关, 从根本上解决了深度 QNN 的内存瓶颈问题. 但 Sharma 等<sup>[99]</sup>证明其仍有贫瘠高原问题. 此外还有 Bausch 等<sup>[100]</sup>用于序列数据的循环量子神经网络 (recurrent quantum neural networks, QRNN), 以及 Nguyen 等<sup>[101]</sup>利用对称性先验的等变量子神经网络 (equivariant quantum neural networks, EQNN).

为了从根本上克服深度量子线路中的退相干积累与非线性实现难题, 研究人员开始探索基于测量的仿生混合架构. Zhou 等<sup>[102]</sup>提出了一种“软量子神经元”(soft quantum neuron) 模型. 与依赖全局相干演化的传统 QNN 不同, 该模型借鉴了生物神经元的信号传递机制, 利用经典控制的单比特操作和测量结果来连接神经元. 这种测量-前馈机制自然地引入了非线性, 且无需维持长程纠缠, 从而极大地降低了对量子相干性的严苛要求. 实验表明, 基于软量子神经元的网络在手写数字识别等任务中展现了卓越的抗噪能力, 即使在极高的相位翻转噪声环境下也能维持稳健的性能, 为构建低相干需求、类脑形态的量子计算系统提供了新方向.

值得注意的是, 在探索 NISQ 时代的硬件高效架构时, 除了主流的门模型外, 基于量子行走 (quantum walks) 的神经网络架构正成为一种极具潜力的新范式. Wang 等<sup>[103,104]</sup>提出了一种基于量子随机行走 (quantum stochastic walks) 的量子随机神经网络. 该架构通过调节图结构中的哈密顿量耦合与 Lindblad 耗散项, 实现了对函数逼近和数据分类的高效处理. 研究表明, 这种利用耗散动力学的模型在面对标签噪声和设备噪声时, 比传统封闭系统酉演化模型具有更强的鲁棒性. 进一步地, 针对量子线路深度过深的问题, Lin 等<sup>[105]</sup>证明了在简单环形图上进行的离散时间量子行走具有通用计算能力, 能够实现任意的酉变换  $U(N)$  而无需分解

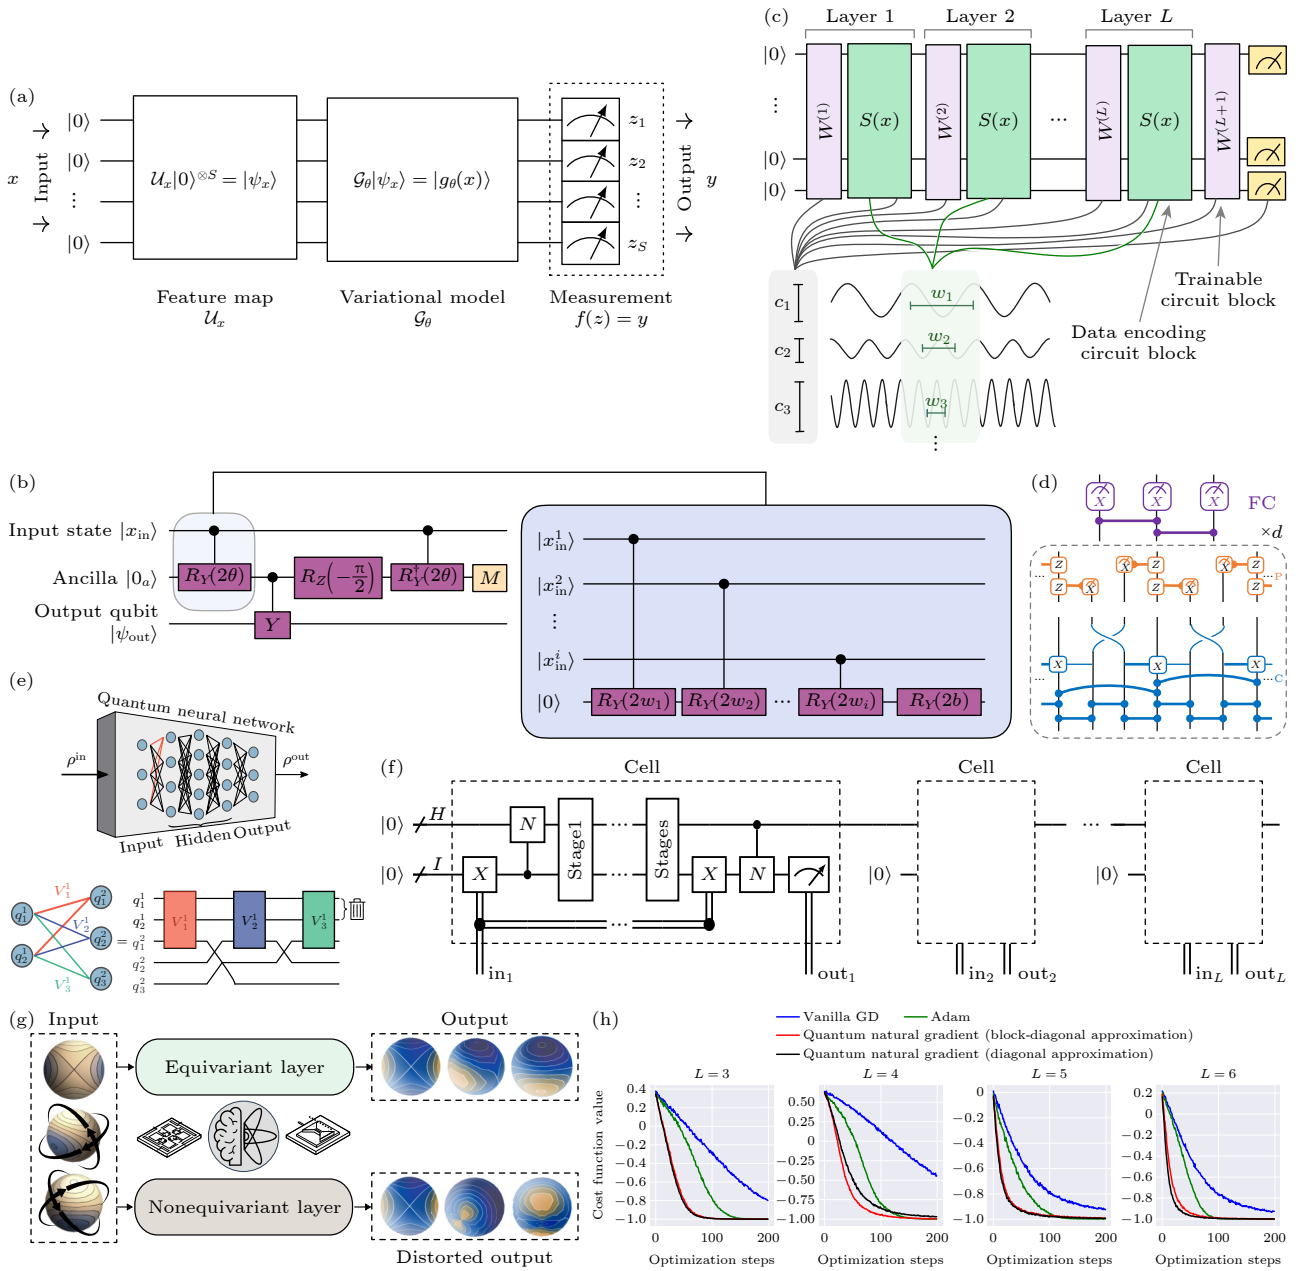


图 16 QNN 关键概念与架构 (a) 通用 QNN 模型范式<sup>[106]</sup>; (b) 非线性量子神经元电路<sup>[98]</sup>; (c) QNN 表达能力与傅里叶级数<sup>[97]</sup>; (d) QCNN 电路<sup>[96]</sup>; (e) DQNN 架构<sup>[99]</sup>; (f) QRNN 架构<sup>[100]</sup>; (g) 等变层效果对比<sup>[101]</sup>; (h) QNG 收敛对比<sup>[107]</sup>

Fig. 16. Key concepts and architectures of QNN: (a) General QNN model paradigm<sup>[106]</sup>; (b) non-linear quantum neuron circuit<sup>[98]</sup>; (c) QNN expressive power and Fourier series<sup>[97]</sup>; (d) QCNN circuit<sup>[96]</sup>; (e) DQNN architecture<sup>[99]</sup>; (f) QRNN architecture<sup>[100]</sup>; (g) EQNN effect comparison<sup>[101]</sup>; (h) QNG convergence comparison<sup>[107]</sup>.

为传统的量子门序列。这种通过优化节点上的硬币算符来驱动演化的方式极大地简化了物理实现要求。

理论上, Schuld 等<sup>[97]</sup>指出 QNN 的表达能力可用傅里叶级数理解, 其中编码定频率, 线路定系数. 与表达能力紧密相关的是可训练性. Abbas 等<sup>[106]</sup>提出“有效维度”来量化 QNN 的表达能力与可训练性, 证明 QNN 可超越经典网络. 为提升训练效率, Stokes 等<sup>[107]</sup>提出了量子自然梯度

(quantum natural gradient, QNG) 算法, 利用量子信息几何修正梯度, 显著提升了收敛速度。

综上, QNN 是 VQA 框架下的重要分支. 设计具有问题导向的归纳偏置、同时保证可训练性的 QNN 架构, 是当前该领域的研究热点之一。

### 4.1.3 关键挑战——贫瘠高原

“贫瘠高原”(barren plateau) 现象是 QNN 面临的最严峻挑战之一 (其机理与主要缓解策略概览

见图 17). McClean 等<sup>[108]</sup>发现, 对于许多深度随机 PQC, 代价函数梯度的方差会随量子比特数的增加而指数级衰减. 这意味着区分梯度信号与统计

噪声所需的测量次数必须指数级增长, 从而抵消了量子计算的潜在优势. 这一现象的根源在于深度随机线路的强表达能力. McClean 等<sup>[108]</sup>的研究表明,

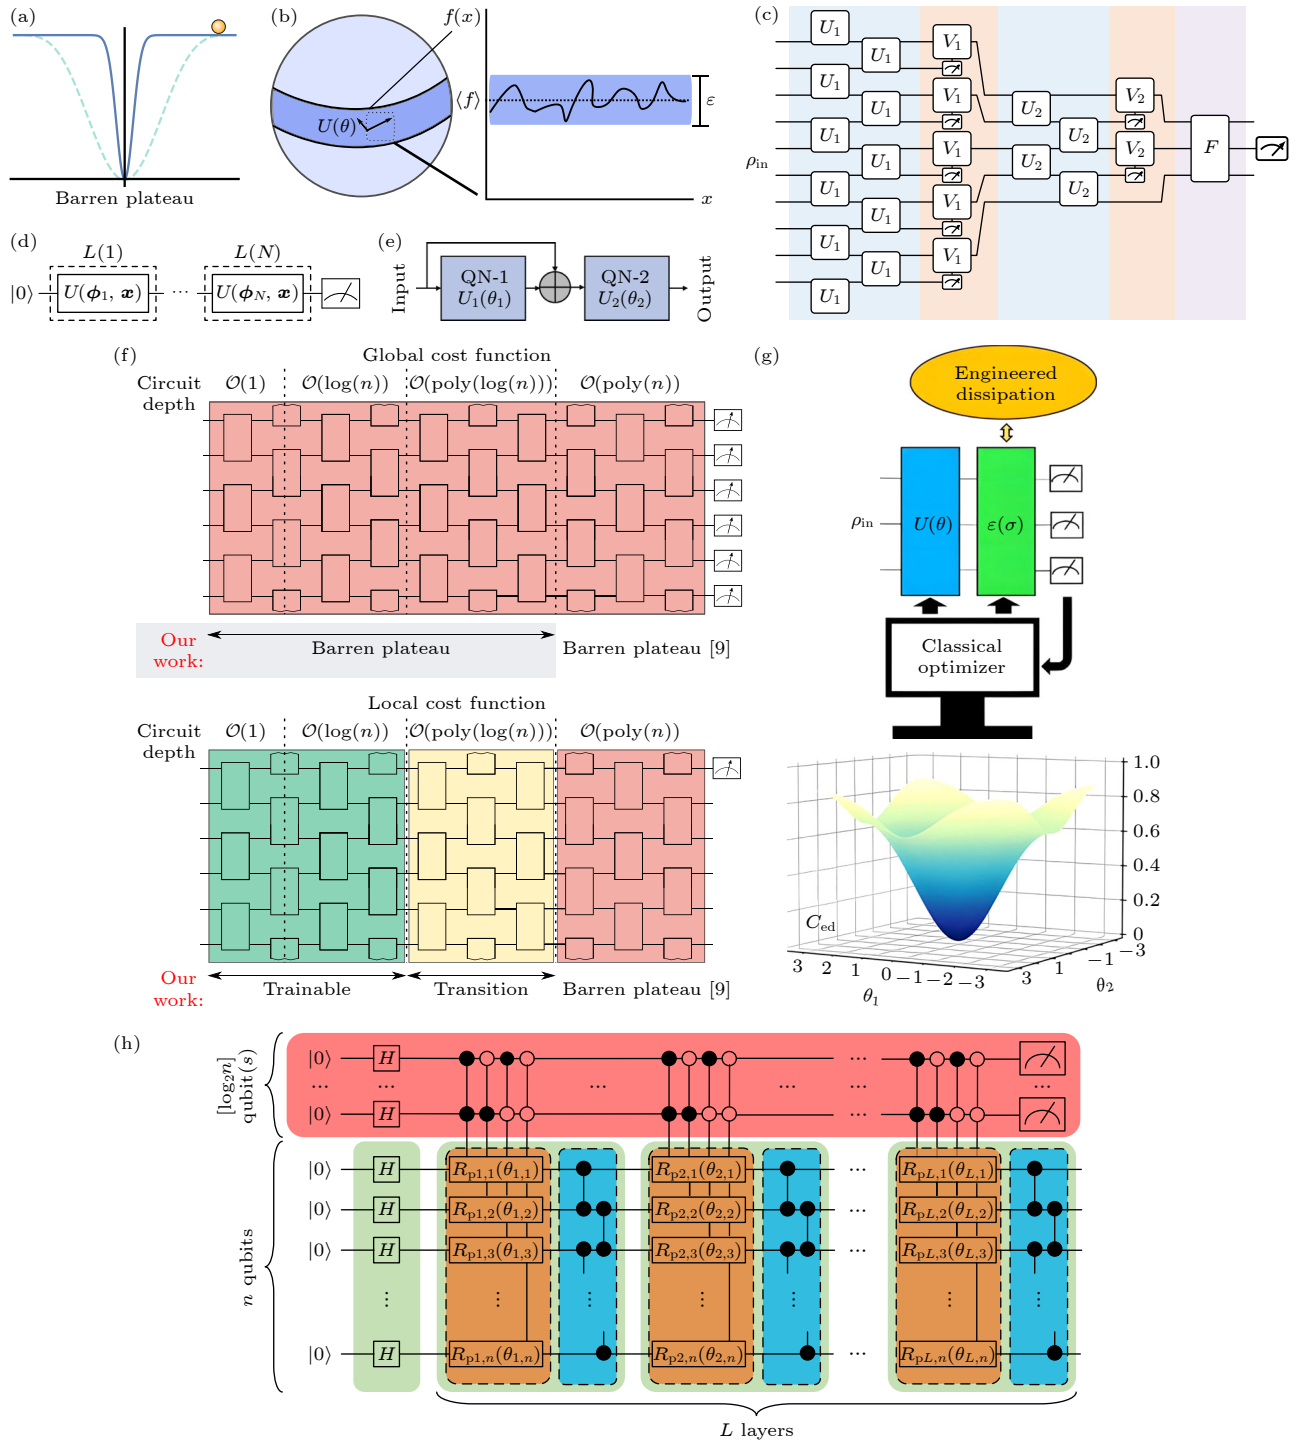


图 17 贫瘠高原现象及其主要缓解策略 (a) 贫瘠高原示意图<sup>[111]</sup>; (b) 贫瘠高原的几何解释 (测度集中)<sup>[108]</sup>; (c) QCNN 架构<sup>[96]</sup>; (d) 数据重上传分类器架构<sup>[113]</sup>; (e) ResQNet 架构<sup>[114]</sup>; (f) 局部 (可训练) 与全局 (贫瘠) 代价函数<sup>[109]</sup>; (g) 工程化耗散架构<sup>[110]</sup>; (h) 辅助量子比特控制架构<sup>[115]</sup>

Fig. 17. The barren plateau phenomenon and key mitigation strategies: (a) Schematic of a barren plateau landscape<sup>[111]</sup>; (b) geometric interpretation of barren plateaus (concentration of measure)<sup>[108]</sup>; (c) QCNN architecture<sup>[96]</sup>; (d) data Re-uploading Classifier architecture<sup>[113]</sup>; (e) quantum Residual Network (ResQNet) architecture<sup>[114]</sup>; (f) local (trainable) vs. Global (barren) cost functions<sup>[109]</sup>; (g) engineered Dissipation architecture<sup>[110]</sup>; (h) auxiliary Qubit Control architecture<sup>[115]</sup>.

当一个线路的随机性足以使其构成一个“酉 2-设计”(unitary 2-design) 时, 它就会表现出贫瘠高原. 这揭示了一个核心矛盾: 理论上表达能力越强的线路, 在实践中反而越难训练.

随后的研究深化了此理解. Cerezo 等<sup>[109]</sup> 证明了贫瘠高原具有“代价函数依赖性”, 即使是浅层线路, 若采用全局代价函数 (测量所有量子比特) 依然存在贫瘠高原. 相反, 若采用局域代价函数 (仅测量少数邻近量子比特), 则在对数深度的线路, 梯度仅多项式衰减, 保障了可训练性. 此外, 量子噪声本身也会诱发贫瘠高原, 使梯度随线路深度指数衰减, 加剧训练难度<sup>[110]</sup>.

为克服贫瘠高原, 研究界从架构设计和优化策略两个层面提出了方案.

在架构创新方面, 研究转向设计具有特定问题结构和归纳偏置的 Ansatz<sup>[111]</sup>. QCNN 是此方向的里程碑式进展, 由 Cong 等<sup>[96]</sup> 提出. 它采用分层的卷积层和池化层, 内在保持了信息的局域性. Pesah 等<sup>[112]</sup> 严格证明 QCNN 可避免或显著缓解贫瘠高原, 其梯度方差至多是多项式衰减.

另一种新颖架构是 Pérez-Salinas 等<sup>[113]</sup> 提出

的数据重上传分类器. 它利用极少 (甚至单个) 量子比特, 在线路层之间反复编码经典数据, 用深度换取了复杂性.

一系列优化策略也被提出来, 研究人员探索了参数初始化策略、层级化训练以及量子残差网络 (quantum residual networks, ResQNETs)<sup>[114]</sup> 等方法, 旨在改善梯度在深层线路中的传播. Sannia 等<sup>[110]</sup> 提出了工程化耗散, 通过在每层后引入可训练的马尔可夫损耗, 将全局代价函数有效映射为局域代价函数; 而 Yao 和 Hasegawa<sup>[115]</sup> 提出了辅助量子比特与纠缠控制策略, 通过引入辅助比特将线路从酉 2-设计转变为更易训练的酉 1-设计, 并在训练后移除这些辅助比特.

#### 4.1.4 量子核方法

在面向 NISQ 时代的 QML 算法中, 量子核方法 (quantum kernel methods) 极具前景. 它借鉴了经典“核技巧”, 即通过非线性映射将数据映射到高维特征空间, 使数据线性可分<sup>[93]</sup> (其基本原理与挑战概览见图 18).

量子核方法的核心是利用量子计算机来构建一个强大的特征映射, 将经典数据映射到高维希尔

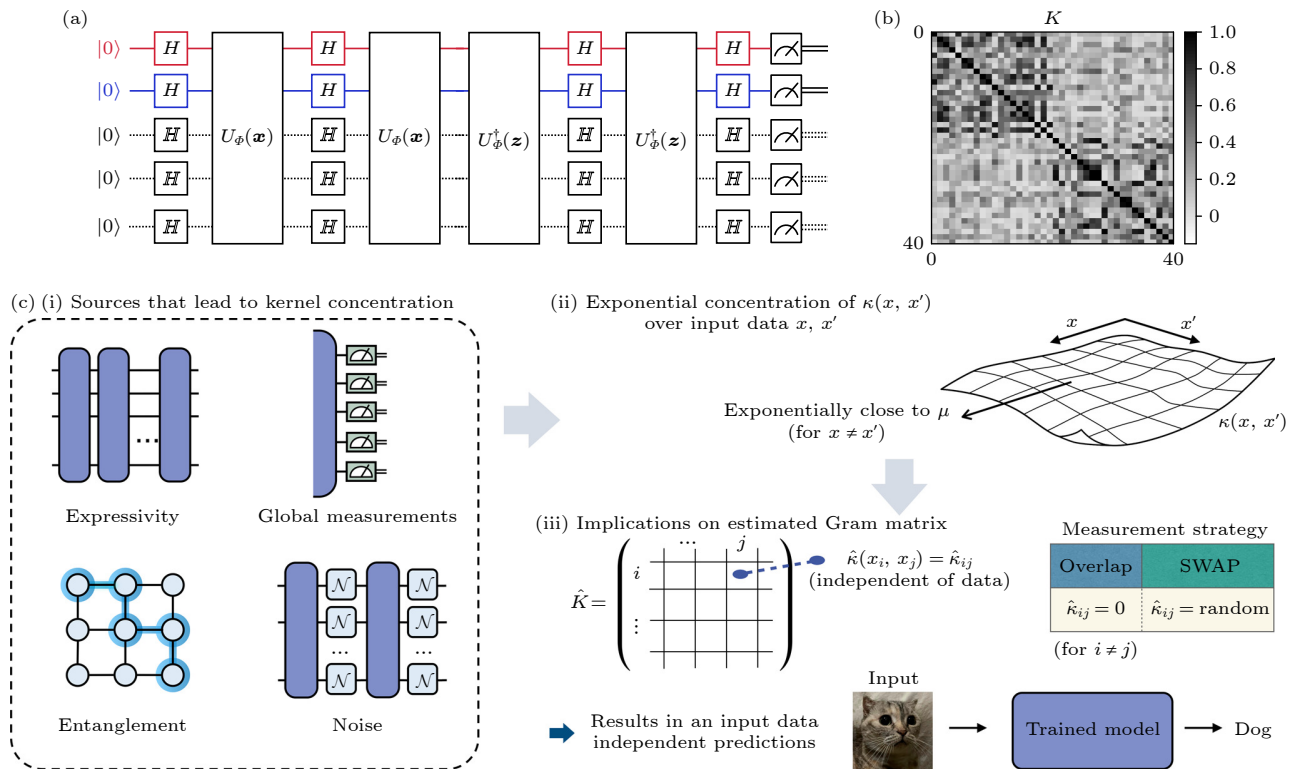


图 18 量子核方法的原理与指数浓度挑战 (a) 估算核函数的量子线路<sup>[93]</sup>; (b) 理想的核矩阵<sup>[93]</sup>; (c) 核函数指数浓度现象示意图<sup>[116]</sup>  
 Fig. 18. Principle of the quantum kernel method and the exponential concentration challenge: (a) Quantum circuit for estimating the kernel function<sup>[93]</sup>; (b) ideal kernel matrix<sup>[93]</sup>; (c) illustration of the exponential concentration phenomenon<sup>[116]</sup>.

伯特空间,其主要任务是高效估算特征向量的内积(即核函数).计算出的核矩阵随后交由经典 SVM 求解器进行训练.这种模块化分工利用了量子计算机在高维空间操作的优势,并将凸优化留给经典计算机处理,降低了算法对硬件噪声和优化难题的敏感度.

Havlíček 等<sup>[93]</sup>率先提出此方法,并在超导量子处理器上进行了实验验证.明确了实现量子优势的必要条件:所构造的量子核函数必须是经典计算机难以计算的.如果特征映射仅产生可被经典模拟的乘积态,则无法带来量子优势.

尽管量子核方法因其训练的凸优化特性备受关注,但它面临“指数浓度”的挑战,Thanasilp 等<sup>[116]</sup>系统地揭示了该现象:随比特数  $n$  增加,不同的数据点对  $(x_i, x_j)$  的核函数值  $K(x_i, x_j)$  会指数级地集中到一个与数据无关的固定值(通常接近于 0).这使得核矩阵变得“平凡”,不再包含有用的数据信息.

Thanasilp 等识别了导致核函数浓度的四个主要来源.

数据编码的表达能力:过强的特征映射(高表达能力)会将不同输入映射到高维空间中近乎正交的随机向量上,使其内积趋近于 0.

全局测量:估算核函数的标准方法(如 SWAP 测试)依赖全局测量,这会平均掉数据编码产生的局部特征信息.

纠缠:大量纠缠会加速量子态的“伪随机化”,加剧其正交性,促进浓度发生.

噪声:NISQ 设备中的噪声会使量子态趋向于最大混合态,导致其内积(保真度)收敛到一个固定的、与数据无关的小值.

核函数浓度的后果是灾难性的.在有限测量次数下,统计噪声将远大于核函数值间的微小差异,导致训练出的模型丧失泛化能力.因此,避免浓度的关键在于精心设计具有特定结构、问题启发式且纠缠较少的特征映射电路.

近期的实证研究通过特征工程与算法优化在药物发现领域验证了量子核方法的可行性.Pallavi 等<sup>[117]</sup>提出的 QKDTI 框架通过引入 Nyström 近似技术,有效地降低了计算复杂度并提升了扩展性,在药物-靶标相互作用预测中实现了优于经典 SVR 和深度学习模型的准确率.与此同时,针对 NISQ 设备的比特数限制与噪声问题,Bhatia

等<sup>[118]</sup>采用主成分分析将高维分子指纹大幅降维,从而规避了高表达能力可能引发的浓度问题,展现了量子支持向量分类器在噪声环境下的鲁棒性与潜在优势.这些工作共同表明,结合降维预处理与核矩阵近似是克服指数浓度问题、在特定领域实现量子优势的有效路径.

## 4.2 量子规划与组合优化

本节将探讨量子计算在确定性求解问题上的应用:量子规划与组合优化.与 QML 学习模式不同,该领域旨在从巨大的离散可能性中找出满足约束的最优解,这对于自动化规划、调度和物流等 AI 关键问题至关重要.其核心挑战在于计算复杂性,许多关键问题本质上是 NP 难(nondeterministic polynomial-time hard)问题<sup>[119]</sup>.经典计算机寻找精确解的时间随问题规模指数级增长,这构成了经典 AI 在决策和资源管理上的根本瓶颈.

本节将探讨两大主流范式.一是量子退火(quantum annealing, QA),一种模拟量子绝热演化寻找最优解的元启发式算法<sup>[15]</sup>;二是量子近似优化算法(quantum approximate optimization algorithm, QAOA),一种专为门模型计算机设计的混合变分算法<sup>[16]</sup>.本文将分析二者的原理、应用,并探讨其在 NISQ 时代的挑战与未来方向.

### 4.2.1 量子退火

QA 是求解优化问题的计算模型(核心概念与应用流程参见图 19),可以看作是受绝热量子计算思想启发的模拟式启发优化范式,其核心是利用量子涨落寻找全局最小值.该理论由 Kadowaki 和 Nishimori<sup>[15]</sup>提出,利用量子隧穿效应,使系统能穿越能量壁垒,逃离传统模拟退火(simulated annealing, SA)会陷入的局部最优解.整个退火过程由一个时变哈密顿量  $H(t) = A(t)H_D + B(t)H_P$  控制,  $H_P$  是待解决问题的哈密顿量,通常是经典的伊辛模型.  $H_D$  是具有简单基态的驱动哈密顿量,它与  $H_P$  不对易.通常为横向场  $H_D = -\sum_j \sigma_j^x$ ,其中  $\sigma_j^x$  是作用在第  $j$  个量子比特上的泡利- $X$  算符.调度函数  $A(t)$  和  $B(t)$  在退火开始( $t_i$ )时设置为  $A(t_i) \gg B(t_i)$ ,使系统处在  $H_D$  的基态;在退火结束( $t_f$ )时演变为  $A(t_f) \ll B(t_f)$ ,使系统趋近于  $H_P$  的基态.

根据量子绝热定理,当演化足够缓慢时系统将

始终保持在瞬时基态上. 演化速度取决于瞬时基态与第一激发态之间的能量差, 即瞬时能量隙  $\Delta(t)$ . 当驱动项和问题项强度相当时, 系统常常会经历量子相变 (quantum phase transition, QPT), 此时  $\Delta(t)$  会随着系统规模增大而趋于关闭, 算法效率随问题规模下降, 严重制约 QA 性能.

QA 的优势在于其独特的隧穿机制. SA 依赖热涨落跳过能垒, 而 QA 利用量子隧穿“穿透”能

垒, 对于又高又窄的能垒, 隧穿成功率远高于热跳跃. QA 的实际应用在很大程度上取决于一个经典预处理: 将抽象优化问题转化为物理系统可模拟的数学形式. 目前, 标准模型是伊辛模型或其等价的二次无约束二元优化 (quadratic unconstrained binary optimization, QUBO) 问题 [120]. QUBO 要求将所有变量映射为二元变量, 并将目标函数和约束编码成一个二次多项式. 其最小值对应最优解.

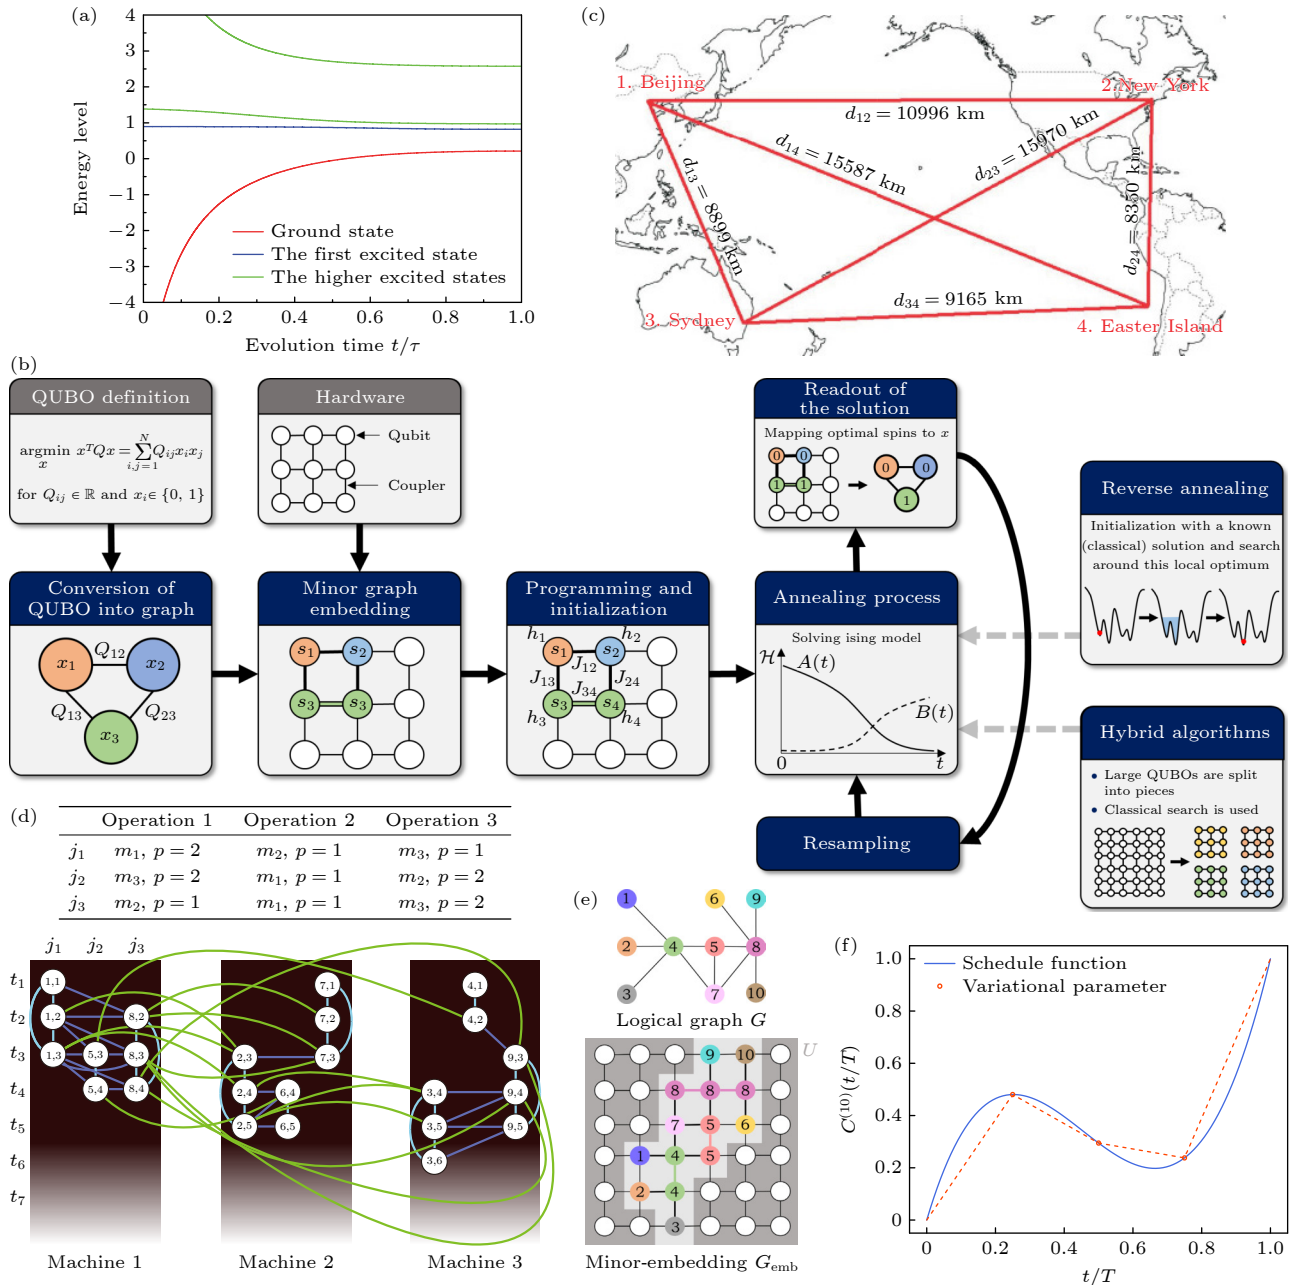


图 19 量子退火核心概念与应用流程示意图 (a) 量子退火过程中的能谱演化与能量隙 [121]; (b) QUBO 建模与量子退火工作流程 [124]; (c) TSP 实例 [121]; (d) JSSP 及其 QUBO 图形 [122]; (e) 将逻辑图嵌入硬件的次要嵌入过程 [124]; (f) 变分优化的非单调退火调度 [125]

Fig. 19. A schematic diagram illustrating the core concepts and application workflow of quantum annealing: (a) Energy spectrum evolution and energy gap in QA [121]; (b) QUBO modeling and QA workflow [124]; (c) TSP example [121]; (d) JSSP and its QUBO graph [122]; (e) minor embedding process mapping logical graphs onto hardware [124]; (f) variational optimized non-monotonic annealing schedule [125].

Lucas<sup>[119]</sup>的里程碑式工作系统性展示了如何将众多 NP 难题映射为 QUBO, 拓展了 QA 的边界. 但高效的 QUBO 建模本身仍是一个瓶颈.

QA 已用于解决复杂调度问题. Chen 等<sup>[121]</sup>利用核磁共振模拟器求解了旅行商问题 (traveling salesman problem, TSP). 工业级的作业车间调度 (job-shop scheduling problem, JSSP) 和车辆路径问题 (vehicle routing problem, VRP) 也通过引入惩罚项被构建为 QUBO 模型<sup>[122]</sup>. 此外, 在生命科学领域, Doga 等<sup>[123]</sup>研究了利用量子计算解决蛋白质结构预测问题, 并在对比研究中指出, 虽然 QA 可用于此类晶格模型求解, 但将高阶相互作用转化为 QUBO 形式会带来显著的资源开销, 在处理复杂生物分子构象时面临比门电路量子计算更严峻的扩展性挑战.

然而, 当前 NISQ 时代, 商用量子退火设备依然面临硬件限制<sup>[124]</sup>. 最核心挑战之一是次要嵌入 (minor embedding) 问题. 物理量子比特的连接拓扑 (如 Pegasus) 是稀疏的, 很少能与问题的变量耦合图 (逻辑图) 直接匹配. 因此一个逻辑变量通常需要由多个通过强铁磁耦合连接在一起的物理量

子比特组成的“链”来表示. 这不仅消耗资源, 且易因噪声断裂. 此外, QA 性能还极其依赖于退火调度, 即系统从初始哈密顿量演化到问题哈密顿量的速率和路径, 经过优化的非单调退火路径被证明能极大提升成功率<sup>[125]</sup>.

### 4.2.2 量子近似优化算法

QAOA 是门模型量子计算机上解决组合优化问题的领军算法<sup>[126]</sup>(算法核心概念与典型应用见图 20), 由 Farhi 等<sup>[16]</sup>提出. QAOA 采用混合量子-经典框架: 量子处理器执行参数化线路并测量代价函数, 经典优化器根据反馈迭代调整参数以求近似最优解.

QAOA 的线路结构灵感源自绝热量子计算的离散化模拟<sup>[16]</sup>. 标准线路包含  $p$  层交替演化: 由编码问题的哈密顿量  $H_C$  驱动的演化  $U_C(\gamma) = e^{-i\gamma H_C}$ , 以及由混合哈密顿量  $H_M$  驱动的演化  $U_M(\beta) = e^{-i\beta H_M}$ <sup>[127]</sup>.  $H_M$  的标准选择是作用在量子比特上的泡利- $X$  算子之和:  $H_M = \sum_i \sigma_i^x$ . 整个线路的动力学行为由  $2p$  个经典优化器需要优化的变分参数  $\gamma = (\gamma_1, \dots, \gamma_p)$  和  $\beta = (\beta_1, \dots, \beta_p)$  决定. QAOA 的

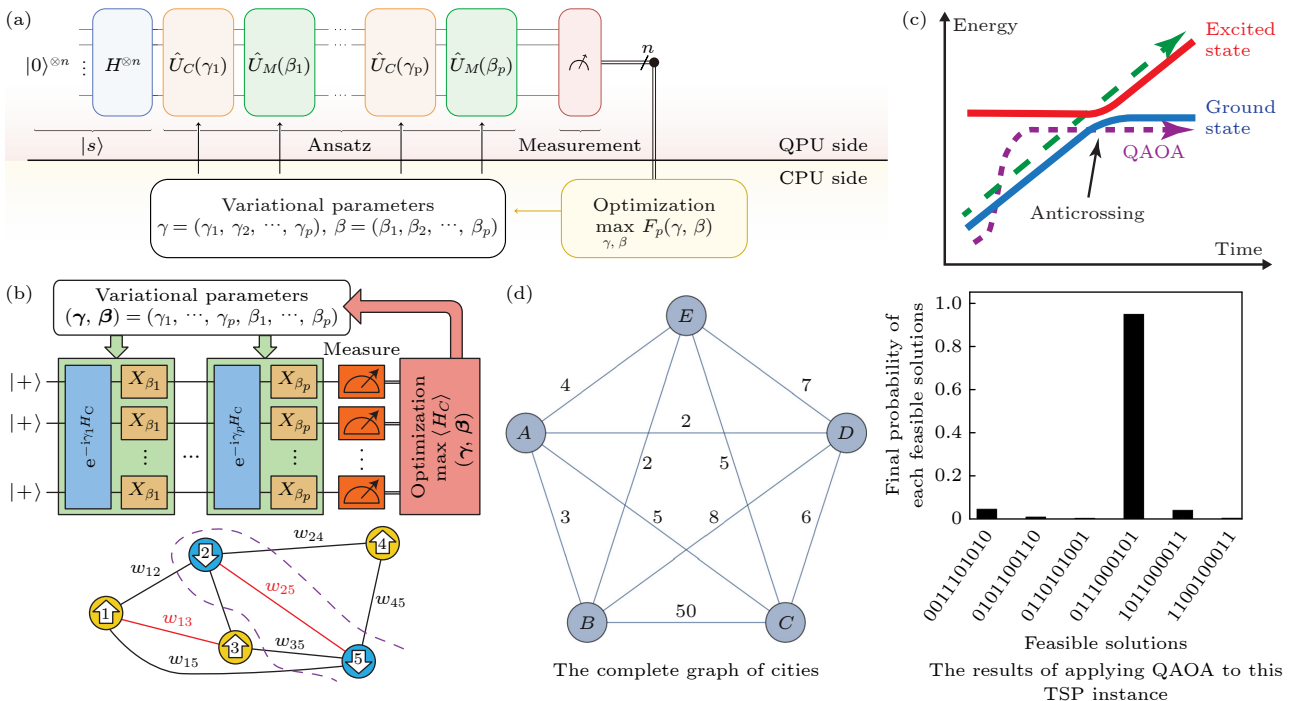


图 20 QAOA 核心概念与应用 (a) QAOA 混合量子-经典框架<sup>[126]</sup>; (b) QAOA 线路结构及 Max-Cut 应用<sup>[128]</sup>; (c) QAOA 利用非绝热捷径克服小能隙的机制<sup>[128]</sup>; (d) QAOA 解决 TSP 实例<sup>[129]</sup>

Fig. 20. Core concepts and applications of QAOA<sup>[126]</sup>: (a) Hybrid quantum-classical framework of QAOA; (b) QAOA circuit structure and Max-Cut application<sup>[128]</sup>; (c) mechanism of QAOA utilizing non-adiabatic shortcuts to overcome small energy gaps<sup>[128]</sup>; (d) example of QAOA solving the TSP<sup>[129]</sup>.

经典基准问题是最大割 (max-cut) 问题, 因其代价函数可以被自然地映射为伊辛哈密顿量:  $H_C = \frac{1}{2} \sum_{(i,j)} (1 - \sigma_i^z \sigma_j^z)$ , 成为检验 QAOA 性能的理想平台<sup>[128]</sup>.

QAOA 的性能随深度  $p$  提升,  $p \rightarrow \infty$  极限下, 可被视作对绝热路径的离散化近似. 但实际应用中,  $p$  值较大时优化  $2p$  个参数是极大挑战. Zhou 等<sup>[128]</sup> 对 QAOA 在 Max-Cut 问题上进行深入研究, 开发了高效参数优化启发式策略, 并发现利用非绝热动力学捷径可在硬实例上实现加速求解. 为克服标准 QAOA 的局限, 多种 QAOA 变体被发展. 如 Blekos 等<sup>[126]</sup> 综述的多角度 QAOA (multi-angle QAOA)、温启动 QAOA (warm-starting QAOA) 及自适应 QAOA (ADAPT-QAOA) 等, 旨在用更浅的线路实现更优性能.

QAOA 已扩展应用于多种复杂问题, 包括 TSP<sup>[129]</sup>, VRP<sup>[130]</sup>, 以及 JSSP. 例如, Ruan 等<sup>[129]</sup> 通过将约束编码进混合哈密顿量而非传统的惩罚项来解决 TSP. 这些应用展示了 QAOA 的潜力, 但也突显了其在当前硬件下面临的扩展性挑战.

### 4.3 高级量子智能: 感知、交互与协作

高级智能不仅需要高效计算, 更需具备与复杂真实世界交互的能力. 这要求系统拥有类似生物的认知功能. 本节将探讨“高级量子智能”这一前沿领域, 涵盖三个核心支柱: 智能体如何理解视觉世界, 主要涉及量子计算机视觉 (quantum computer vision, QCV); 智能体如何运用语言沟通, 主要涉及量子自然语言处理 (quantum natural language processing, QNLP); 多个智能体如何协调行动, 主要涉及量子多智能体系统 (quantum multi-agent systems, QMAS).

#### 4.3.1 量子计算机视觉

QCV 旨在利用量子计算突破经典视觉瓶颈<sup>[131]</sup>. 首要挑战在于量子图像表示 (quantum image representation, QIR), 关键概念与应用范例见图 21, 研究人员已提出多种 QIR 模型, 它们在量子比特成本、电路深度和信息保真度之间存在不同的权衡<sup>[132]</sup>. 尽管在 NISQ 时代进行全图处理十分困难, 研究人员已开始探索将特定量子算法应用于核心视觉任务. 例如, Yao 等<sup>[132]</sup> 提出的量子边缘检测算法已在理论上实现了指数级加速. 在此基础上, 随着研

究的深入, QCV 正从简单的边缘检测向更复杂的高级特征表征迈进. Ji 等<sup>[133]</sup> 提出了一种基于量子网络的量子稀疏编码 (quantum sparse coding, QSCD) 框架. 该工作构建了一个由多层双能级酉变换组成的对称量子神经网络, 专门用于执行图像和量子态的稀疏表征与重建. 通过结合量子自然梯度下降算法, 该模型在灰度图像重建任务中实现了高达 98.77% 的精度, 并能以极高的保真度复原复杂量子态. 这一成果成功将经典视觉中的稀疏编码原理映射到量子硬件上, 证明了量子神经网络处理高维视觉数据特征提取与压缩的可行性, 为未来构建全量子视觉系统提供了关键的算法组件.

目前, QCV 领域最具前景的范式是混合量子-经典模型, Srivastava 等<sup>[134]</sup> 应用结合迁移学习和量子神经网络的混合模型于脑肿瘤分类, 凸显了 QCV 在辅助医疗诊断方面的巨大潜力. 在几何模型鲁棒拟合领域, Pandey 等<sup>[135]</sup> 利用量子退火机解决了含离群点的多模型拟合. Yang 等<sup>[136]</sup> 则首次在门模型量子计算机上演示了鲁棒拟合. 此外, Meli 等<sup>[137]</sup> 提出了基于绝热量子计算的点集配准迭代方法. 这些研究共同证明, 量子优化算法能够有效地解决计算机视觉流程中复杂的底层优化问题.

#### 4.3.2 量子自然语言处理

量子自然语言处理 (QNLP) 旨在克服传统统计模型在语法逻辑上的局限, 将语言的组合结构直接映射到量子物理结构上<sup>[138,139]</sup> (核心处理流程见图 22), 其核心理论是 Coecke 等<sup>[140]</sup> 提出的分布-组合-范畴 (distributional compositional categorical, DisCoCat) 模型. 该模型利用与量子力学同框架的数学工具, 即紧致闭范畴 (compact-closed categories), 将句子的语法分析表征为弦图, 从而实现从语法范畴到语义范畴的映射<sup>[141]</sup>.

为克服 Zeng 和 Coecke<sup>[142]</sup> 的早期方案对尚未成熟的量子随机存取存储器的依赖, Meichanetzidis 等<sup>[139]</sup> 引入了参数化量子电路. 在这种新范式中, 词的意义被直接编码为量子电路中的可训练参数. 这些参数随后可通过经典优化器在特定任务下进行训练, 形成了混合量子-经典模型. 这一方法的可行性迅速在真实量子硬件上得到了验证. Meichanetzidis 等<sup>[143]</sup> 完成了首个在 NISQ 设备上的概念验证实验. Lorenz 等<sup>[144]</sup> 则首次在 IBM 量子计算机上成功进行了规模超过百句的实验.

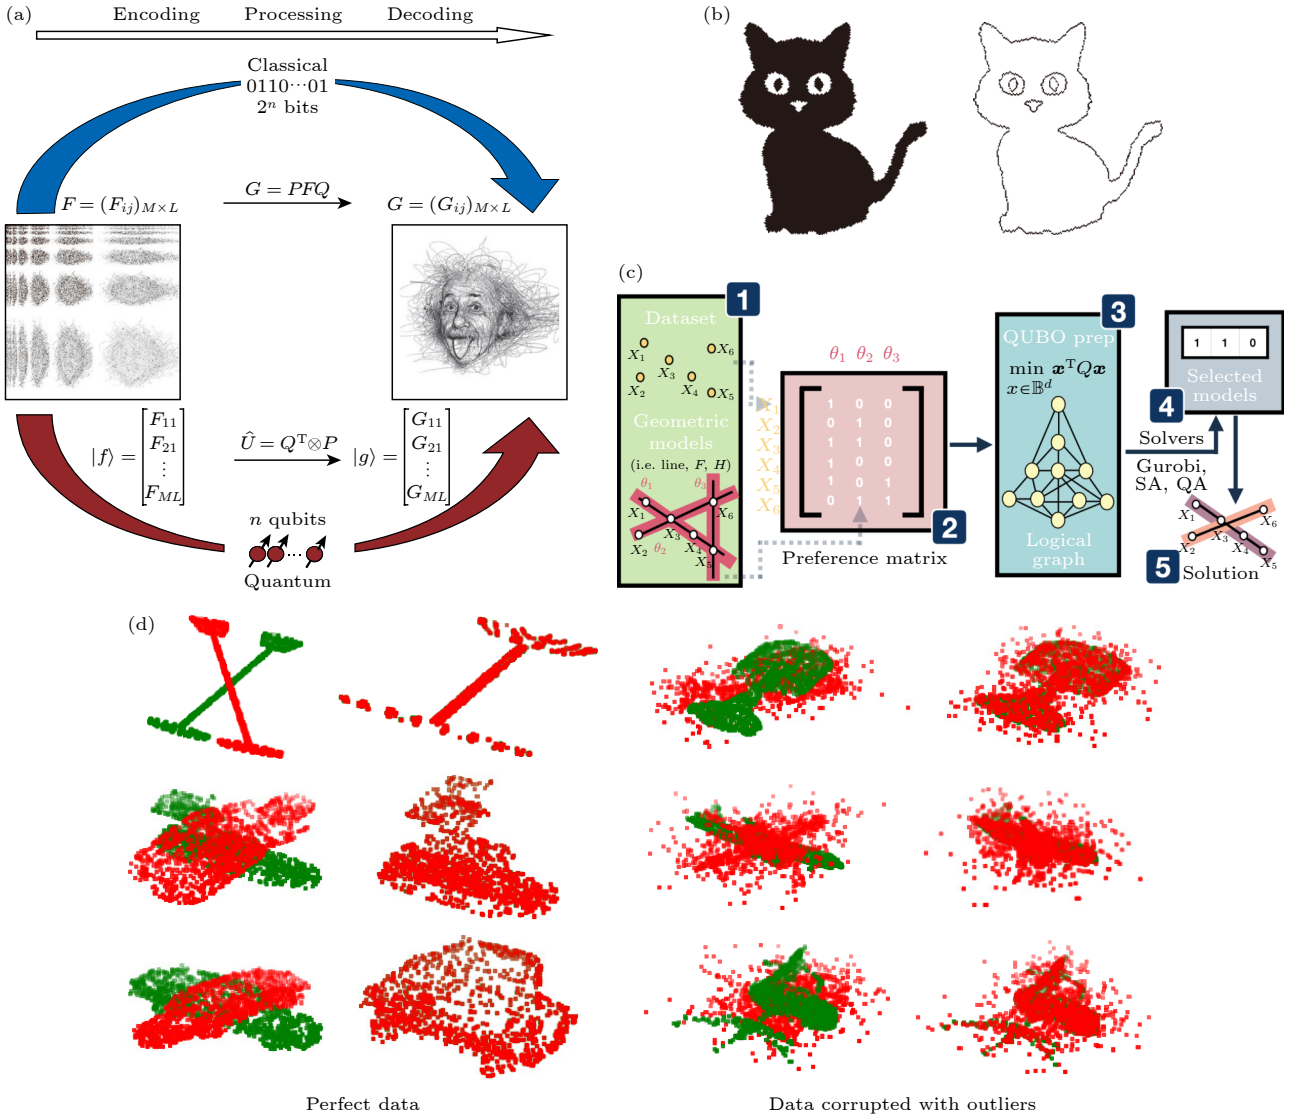


图 21 QCV 关键概念与应用范例 (a) 经典与量子图像处理流程对比<sup>[132]</sup>; (b) 量子边缘检测算法应用<sup>[132]</sup>; (c) 基于量子退火的鲁棒多模型拟合<sup>[135]</sup>; (d) 高离群率下的迭代量子变换估计<sup>[137]</sup>

Fig. 21. Key concepts and application paradigms of QCV: (a) Classical vs. quantum image processing<sup>[132]</sup>; (b) quantum edge detection application<sup>[132]</sup>; (c) robust multi-model fitting via quantum annealing<sup>[135]</sup>; (d) iterative quantum transformation estimation under high outlier ratios<sup>[137]</sup>.

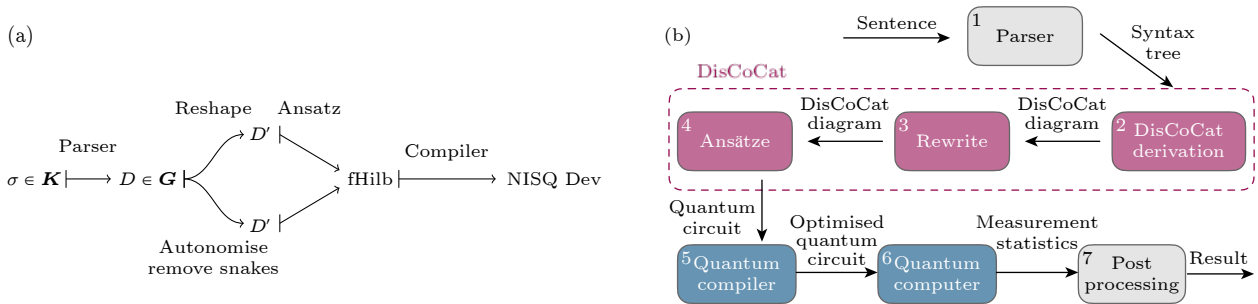


图 22 QNLP 流程示意图 (a) 句法结构到量子态的映射<sup>[139]</sup>; (b) 句子编译与执行的工作流<sup>[144]</sup>

Fig. 22. QNLP pipeline schematic: (a) Theoretical mapping from syntax to quantum states<sup>[139]</sup>; (b) general workflow for sentence compilation and execution<sup>[144]</sup>.

QNLP 的 DisCoCat 框架本质上是一种神经符号混合架构, 为融合符号 AI 的可解释性和连接主义 AI 的经验学习能力提供了一条全新的、基于物理原理的路径<sup>[139]</sup>.

### 4.3.3 量子多智能体系统

多智能体强化学习 (multi-agent reinforcement learning, MARL) 在处理复杂动态环境中的交互与协作时, 面临维度灾难、环境非平稳性及协调困难等严峻挑战. 随着智能体数量增加, 联合状态-动作空间呈指数级增长, 学习过程难以收敛, 难以实现高效的群体协作与协调<sup>[145]</sup>.

量子计算为解决这些问题提供了新途径, 关键概念、架构与应用示意图图 23. 首先是通过变分量子电路 (variational quantum circuit, VQC) 增强智能体能力. 针对 VQC 训练中的“贫瘠高原”问题,

Kölle 等<sup>[146]</sup>提出了无梯度的演化优化训练方法. 实验在一个名为“金币游戏”的多智能体环境中进行, 结果证明, 该 VQC 智能体能以减少 97.88% 的参数量, 达到与大型经典神经网络相近的性能.

量子计算的另一贡献是利用纠缠实现隐式协调. 基于 Eisert<sup>[147]</sup>等提出的 EWL 量子博弈理论, 共享纠缠态可作为可信“协调者”, 实现经典方法无法达成的帕累托最优均衡<sup>[148]</sup>. DeRieux 和 Saad<sup>[149]</sup>据此提出了采用“纠缠分离式评论家”架构的纠缠量子多智能体强化学习 (entangled quantum MARL, eQMARL) 框架. 实验显示, eQMARL 的收敛速度提升了 17.8% 且中心参数减少了 25 倍. 这种方法的实际应用价值也已在探索之中. 如 Drăgan 等<sup>[150]</sup>设计混合 QMARL 算法, 将其用于优化飞行自组网中的连接性.

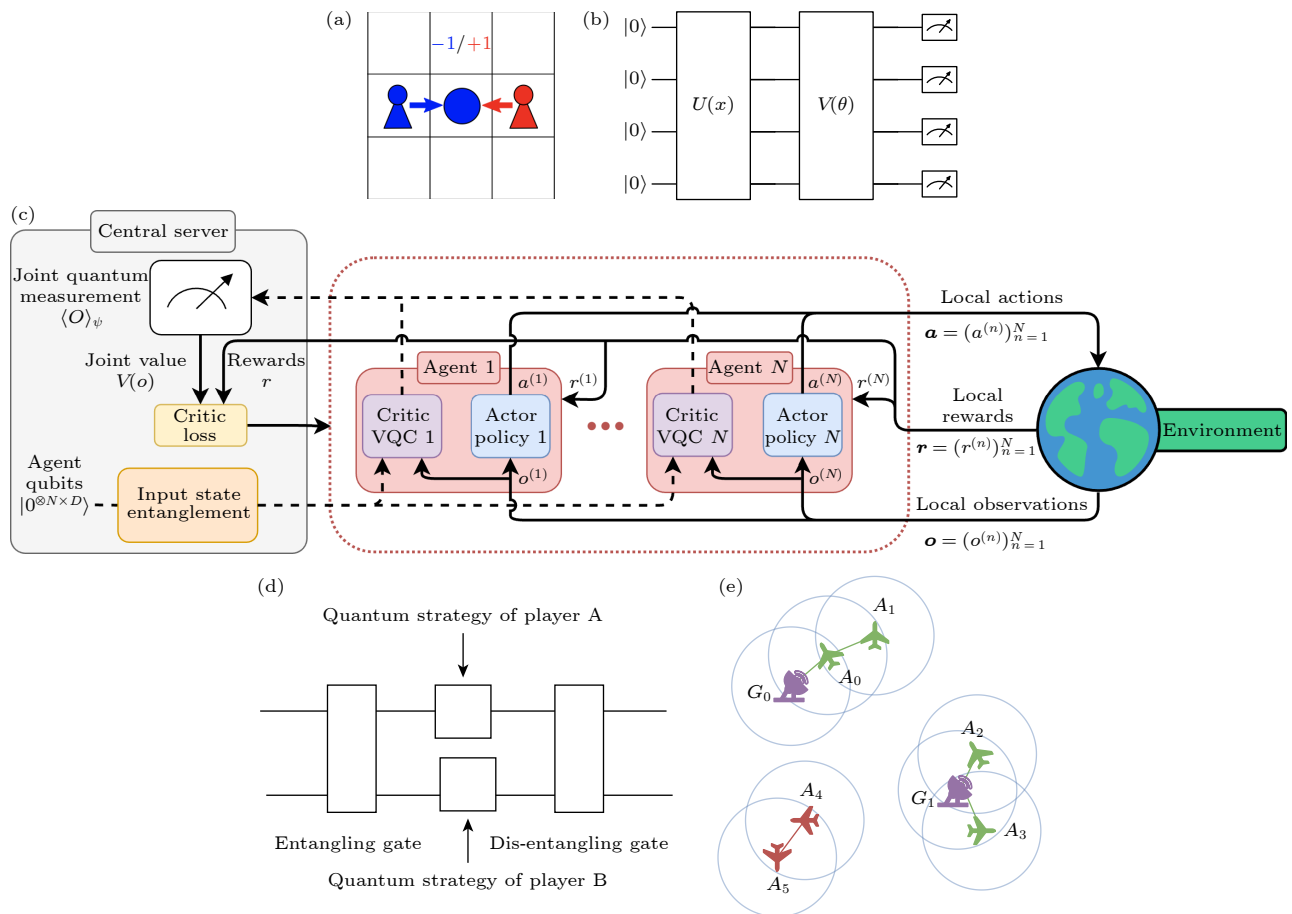


图 23 QMARL 关键概念、框架与应用示意图 (a) 多智能体“金币游戏”环境<sup>[146]</sup>; (b) 变分量子电路基础结构<sup>[146]</sup>; (c) 基于纠缠实现隐式协调的 eQMARL 框架<sup>[149]</sup>; (d) EWL 量子博弈协议<sup>[148]</sup>; (e) QMARL 在飞行自组网的应用<sup>[150]</sup>

Fig. 23. Schematic of key QMARL concepts, frameworks, and applications: (a) Multi-agent “Coin Game” testbed<sup>[146]</sup>; (b) VQC basic structure<sup>[146]</sup>; (c) eQMARL framework for implicit coordination via entanglement<sup>[149]</sup>; (d) EWL quantum game protocol<sup>[148]</sup>; (e) a practical application of QMARL in flying Ad-hoc networks<sup>[150]</sup>.

#### 4.4 小结

本节聚焦“Quantum for AI”，探索量子计算重塑 AI 的路径。核心梳理了量子机器学习从早期理论到 NISQ 时代变分与核方法范式的演进，分析了“贫瘠高原”等训练挑战及结构化应对策略。同时，探讨了用于优化的量子退火与 QAOA，并以量子视觉、自然语言处理及多智能体系统为例，展望了“量子原生”智能架构。

尽管“Quantum for AI”展现了巨大的理论潜力和初步的实验成果，但要实现真正优于经典 AI 的实用化落地，仍需跨越关键技术鸿沟。首先是数据加载问题，海量经典高维数据高效编码为量子态本身可能消耗指数级资源，从而抵消后续处理的量子加速优势。在通用的量子随机存取存储器尚未成熟之前，研发高效的量子特征映射和数据压缩技术，或专注于处理本质上即为量子数据的任务，是规避输入输出瓶颈的务实路径。其次是“贫瘠高原”现象，尽管已出现了几何深度学习和局部代价函数等缓解策略，但在大规模、深层且含噪的量子神经网络中实现稳定训练仍是未解难题。未来的研究需深入探索物理启发的归纳偏置，利用问题的对称性来约束解空间，从而在保持表达能力的同时显著降低优化难度。另外，目前许多 QML 模型仅在合成数据集或小规模问题上展示了效果，缺乏与最先进经典算法在工业级规模问题上的严格对比。未来的方向应从单纯的可行性验证转向追求可证明的量子优势，建立严格的复杂性理论框架，明确界定在哪些特定任务类别和数据分布下，量子 AI 能实现对经典 AI 的超多项式加速或样本复杂度优势。

#### 5 总结与展望

量子计算与人工智能的深度融合，正在推动信息处理与基础科学领域的边界不断拓展。人工智能通过强大的智能控制能力，赋予含噪量子硬件更高的性能与稳定性，而量子计算则利用庞大的希尔伯特空间进行高维信息处理，突破了传统经典 AI 面临的算力瓶颈与模型表达局限。由于其理论上的指数级加速潜力和独特的量子相关性机制，QAI 在解决复杂组合优化和探索全新的量子原生智能架构方面展现出独特优势。同时，随着硬件从 NISQ 时代向容错计算时代过渡，以及高效量子-经典混

合计算生态的成熟，QAI 为未来在药物发现、金融建模等问题上探索更高效方案提供了潜在路径。在实用化进程中，软硬件协同设计的专用算法有望实现从物理层到应用层的全栈优化；而在理论前沿，量子原生模型不仅能为神经-符号融合提供物理基础，可能为基于量子相关性的多智能体协作机制提供新的物理启发与模型原型。

量子人工智能的发展并不是孤立的，而是与其他前沿探索协同发展与进步，包括迈向容错计算的量子纠错技术演进、针对特定应用场景的归纳偏置编码与算法设计、以及管理异构处理器数据流的智能混合编译系统的革新。可以预见的是，量子人工智能技术会在未来几年得到极大的发展，有望在前沿科学探索、工业级问题求解及下一代智能系统的构建中发挥更大的潜力和影响力。

#### 参考文献

- [1] Moore G E 1965 *Electronics* **38** 114
- [2] Moore G E 1975 *International Electron Devices Meeting Washington, DC, U. S. A. December 2-10, 1975* p11
- [3] Feynman R P 2018 *Feynman and Computation* (Boca Raton: CRC Press) p133
- [4] Trimmer J D 1980 *Proc. Am. Philos. Soc.* **124** 323
- [5] Einstein A, Podolsky B, Rosen N 1935 *Phys. Rev.* **47** 777
- [6] Shor P W 1997 *SIAM J. Comput.* **26** 1484
- [7] Georgescu I M, Ashhab S, Nori F 2014 *Rev. Mod. Phys.* **86** 153
- [8] Preskill J 2018 *Quantum* **2** 79
- [9] Schlosshauer M 2007 *Decoherence and the Quantum-to-Classical Transition* (Berlin Heidelberg: Springer)
- [10] Terhal B M 2015 *Rev. Mod. Phys.* **87** 307
- [11] Alexeev Y, Farag M H, Patti T L, et al. 2024 [arXiv: 2411.09131 \[quant-ph\]](#)
- [12] Baum Y, Amico M, Howell S, Hush M, Liuzzi M, Mundada P, Merkh T, Carvalho A R, Biercuk M J 2021 *PRX Quantum* **2** 040324
- [13] Wang Z, Tang H 2024 [arXiv: 2412.20380 \[quant-ph\]](#)
- [14] Biamonte J, Wittek P, Pancotti N, Rebentrost P, Wiebe N, Lloyd S 2017 *Nature* **549** 195
- [15] Kadowaki T, Nishimori H 1998 *Phys. Rev. E* **58** 5355
- [16] Farhi E, Goldstone J, Gutmann S 2014 [arXiv: 1411.4028 \[quant-ph\]](#)
- [17] Klusch M, Lässig J, Müssig D, Macaluso A, Wilhelm F K 2024 *Künstl. Intell.* **38** 257
- [18] Nielsen M A, Chuang I L 2010 *Quantum Computation and Quantum Information* (Cambridge: Cambridge University Press)
- [19] Deutsch D 1985 *Proc. R. Soc. London, Ser. A* **400** 97
- [20] Horodecki R, Horodecki P, Horodecki M, Horodecki K 2009 *Rev. Mod. Phys.* **81** 865
- [21] Farhi E, Goldstone J, Gutmann S, Sipser M 2000 [arXiv: quant-ph/0001106 \[quant-ph\]](#)
- [22] Born M, Fock V 1928 *Z. Phys.* **51** 165
- [23] Albash T, Lidar D A 2018 *Rev. Mod. Phys.* **90** 015002
- [24] Aharonov D, van Dam W, Kempe J, Landau Z, Lloyd S,

- Regev O 2005 arXiv: quant-ph/0405098 [quant-ph]
- [25] Raussendorf R, Briegel H J 2001 *Phys. Rev. Lett.* **86** 5188
- [26] Briegel H J, Browne D E, Dür W, Raussendorf R, van den Nest M V 2009 *Nat. Phys.* **5** 19
- [27] Browne D E, Briegel H J 2006 arXiv: quant-ph/0603226 [quant-ph]
- [28] Hein M, Dür W, Eisert J, Raussendorf R, Nest M, Briegel H J 2006 arXiv: quant-ph/0602096 [quant-ph]
- [29] Raussendorf R 2009 *Int. J. Quantum Inf.* **7** 1053
- [30] Gottesman D 1997 *Ph. D. Dissertation* (Pasadena: California Institute of Technology)
- [31] Walther P, Resch K J, Rudolph T, Schenck E, Weinfurter H, Vedral V, Aspelmeyer M, Zeilinger A 2005 *Nature* **434** 169
- [32] Freedman M H, Kitaev A, Larsen M J, Wang Z 2002 arXiv: quant-ph/0101025 [quant-ph]
- [33] Nayak C, Simon S H, Stern A, Freedman M, Sarma S D 2008 *Rev. Mod. Phys.* **80** 1083
- [34] Read N, Green D 2000 *Phys. Rev. B* **61** 10267
- [35] Kitaev A Y 2003 *Ann. Phys.* **303** 2
- [36] Krenn M, Landgraf J, Foesel T, Marquardt F 2023 *Phys. Rev. A* **107** 010101
- [37] Genois É, Gross J A, Di Paolo A, Stevenson N J, Koolstra G, Hashim A, Siddiqi I, Blais A 2021 *PRX Quantum* **2** 040355
- [38] An Z, Wu J, Lin Z, Yang X, Li K, Zeng B 2025 *Phys. Rev. Lett.* **134** 120202
- [39] Ji Y, Roth M, Kreplin D A, Polian I, Wilhelm F K 2025 arXiv: 2509.12933 [quant-ph]
- [40] Dutt A, Pednault E, Wu C W, Sheldon S, Smolin J, Bishop L, Chuang I L 2023 *Phys. Rev. Res.* **5** 033060
- [41] Zwolak J P, McJunkin T, Kalantre S S, Dodson J P, MacQuarrie E R, Savage D E, Lagally M G, Coppersmith S N, Eriksson M A, Taylor J M 2020 *Phys. Rev. Appl.* **13** 034075
- [42] Sarma B, Hartmann M J 2025 *Phys. Rev. Appl.* **23** 014015
- [43] Stace T M, Chen J, Li L, Perunovic V S, Carvalho A R R, Hush M, Valahu C H, Tan T R, Biercuk M J 2024 *Phys. Rev. Appl.* **21** 014012
- [44] Moon H, Lennon D T, Kirkpatrick J, Van Esbroeck N M, Camenzind L C, Yu L, Vigneau F, Zumbühl D M, Briggs G A D, Osborne M A, Sejdinovic D, Laird E A, Ares N 2020 *Nat. Commun.* **11** 4161
- [45] Schuff J, Carballido M J, Kotzagiannidis M, et al. 2024 arXiv: 2402.03931 [cond-mat]
- [46] Cao S, Zhang Z, Alghadeer M, Fasciati S D, Piscitelli M, Bakr M, Leek P, Aspuru-Guzik A 2025 *Patterns* **6** 101372
- [47] Zwolak J P, Taylor J M 2023 *Rev. Mod. Phys.* **95** 011006
- [48] Maurya S, Mude C N, Oliver W D, Lienhard B, Tannu S 2023 *Proceedings of the 50th Annual International Symposium on Computer Architecture* Orlando, June 17–21, 2023 p89
- [49] Lienhard B, Vepsäläinen A, Govia L C G, et al. 2022 *Phys. Rev. Appl.* **17** 014024
- [50] Chatterjee A, Schwinger J, Gao Y Y 2025 *Phys. Rev. Appl.* **23** 054057
- [51] Guglielmo G D, Du B, Campos J, Boltasseva A, Dixit A, Fahim F, Kudyshev Z, Lopez S, Ma R, Perdue G N, Tran N, Yesilyurt O, Bowring D 2025 *IEEE Trans. Quantum Eng.* **6** 1
- [52] Liao H, Wang D S, Sitdikov I, Salcedo C, Seif A, Mineev Z K 2024 *Nat. Mach. Intell.* **6** 1478
- [53] Cai Z, Babbush R, Benjamin S C, Endo S, Huggins W J, Li Y, McClean J R, O'Brien T E 2023 *Rev. Mod. Phys.* **95** 045005
- [54] Battistel F, Chamberland C, Johar K, Overwater R W J, Sebastiano F, Skoric L, Ueno Y, Usman M 2023 *Nano Futures* **7** 032003
- [55] Bausch J, Senior A W, Heras F J H, Edlich T, Davies A, Newman M, Jones C, Satzinger K, Niu M Y, Blackwell S, Holland G, Kafri D, Atalaya J, Gidney C, Hassabis D, Boixo S, Neven H, Kohli P 2024 *Nature* **635** 834
- [56] Haider N 2024 *Nature* **635** 822
- [57] Gicev S, Hollenberg L C L, Usman M 2023 *Quantum* **7** 1058
- [58] Choukroun Y, Wolf L 2023 arXiv: 2301.11930 [quant-ph]
- [59] Cao H, Pan F, Feng D, Wang Y, Zhang P 2025 arXiv: 2503.21374 [quant-ph]
- [60] Su V P, Cao C, Hu H Y, Yanay Y, Tahan C, Swingle B 2025 *Phys. Rev. Appl.* **23** 034048
- [61] He A Y, Liu Z W 2025 arXiv: 2502.14372 [quant-ph]
- [62] Locher D F, Cardarelli L, Müller M 2023 *Quantum* **7** 942
- [63] Zeng Y, Qin W, Chen Y H, Gneiting C, Nori F 2025 *Phys. Rev. Lett.* **134** 060601
- [64] Xu X Y, Xue X, Chen T, Ding C, Li T, Zhou H, Huang H L, Bao W S 2025 arXiv: 2501.04558 [quant-ph]
- [65] Zheng M, Li A, Terlaky T, Yang X 2023 *ACM Trans. Quantum Comput.* **4** 1
- [66] Riu J, Nogué J, Vilaplana G, Garcia-Saez A, Estarellas M P 2025 *Quantum* **9** 1758
- [67] Ruiz F J R, Laakkonen T, Bausch J, et al. 2025 *Nat. Mach. Intell.* **7** 374
- [68] Fan H, Guo C, Luk W 2022 *DAC '22: 59th ACM/IEEE Design Automation Conference* San Francisco California, CA, July 10–14, 2022 p19
- [69] Ernst J O, Chatterjee A, Franzmeyer T, Kuhn A 2025 arXiv: 2501.14372 [quant-ph]
- [70] Quetschlich N, Burgholzer L, Wille R 2023 *2023 60th ACM/IEEE Design Automation Conference (DAC)* San Francisco, CA, July 9–13, 2023 p1
- [71] Cerezo M, Arrasmith A, Babbush R, Benjamin S C, Endo S, Fujii K, McClean J R, Mitarai K, Yuan X, Cincio L, Coles P J 2021 *Nat. Rev. Phys.* **3** 625
- [72] Ostaszewski M, Trenkwalder L M, Masarczyk W, Scerri E, Dunjko V 2021 arXiv: 2103.16089 [quant-ph]
- [73] Beaudoin C, Ghosh S 2025 arXiv: 2504.20794 [cs]
- [74] Nakaji K, Kristensen L B, Kemmoku R, et al. 2025 arXiv: 2401.09253 [quant-ph]
- [75] Kremer D, Villar V, Vishwakarma S, Faro I, Cruz-Benito J 2024 arXiv: 2407.21225 [quant-ph]
- [76] Roik J, Bartkiewicz K, Černoč A, Lemr K 2021 *Phys. Rev. Appl.* **15** 054006
- [77] Deng D L 2018 *Phys. Rev. Lett.* **120** 240402
- [78] Canabarro A, Brito S, Chaves R 2019 *Phys. Rev. Lett.* **122** 200401
- [79] Ruiz-Gonzalez C, Arlt S, Petermann J, Sayyad S, Jaoumi T, Karimi E, Tischler N, Gu X, Krenn M 2023 *Quantum* **7** 1204
- [80] Torlai G, Mazzola G, Carrasquilla J, Troyer M, Melko R, Carleo G 2018 *Nat. Phys.* **14** 447
- [81] Carrasquilla J, Torlai G, Melko R G, Aolita L 2019 *Nat. Mach. Intell.* **1** 155
- [82] Ahmed S, Sánchez Muñoz C, Nori F, Kockum A F 2021 *Phys. Rev. Lett.* **127** 140502
- [83] Cha P, Ginsparg P, Wu F, Carrasquilla J, McMahon P L, Kim E A 2022 *Mach. Learn. : Sci. Technol.* **3** 01LT01
- [84] Tiunov E S, Tiunova (Vyborova) V V, Ulanov A E, Lvovsky A I, Fedorov A K 2020 *Optica* **7** 448
- [85] Zhu Y, Chen T, Theodorou E A, Chen X, Tao M 2024 arXiv: 2404.06336 [quant-ph]

- [86] Harrow A W, Hassidim A, Lloyd S 2009 *Phys. Rev. Lett.* **103** 150502
- [87] Reberntrost P, Mohseni M, Lloyd S 2014 *Phys. Rev. Lett.* **113** 130503
- [88] Zhou M G, Cao X Y, Lu Y S, Wang Y, Bao Y, Jia Z Y, Fu Y, Yin H L, Chen Z B 2022 *Research* **2022** 9798679
- [89] Gao X, Zhang Z Y, Duan L M 2018 *Sci. Adv.* **4** eaat9004
- [90] Mishra N, Kapil M, Rakesh H, et al. 2021 *Data Management, Analytics and Innovation* (Singapore: Springer Singapore) p101
- [91] Peruzzo A, McClean J, Shadbolt P, Yung M H, Zhou X Q, Love P J, Aspuru-Guzik A, O'Brien J L 2014 *Nat. Commun.* **5** 4213
- [92] Schuld M, Bocharov A, Svore K, Wiebe N 2020 *Phys. Rev. A* **101** 032308
- [93] Havlicek V, Córcoles A D, Temme K, Harrow A W, Kandala A, Chow J M, Gambetta J M 2019 *Nature* **567** 209
- [94] Mitarai K, Negoro M, Kitagawa M, Fujii K 2018 *Phys. Rev. A* **98** 032309
- [95] Beer K, Bondarenko D, Farrelly T, Osborne T J, Salzmann R, Scheiermann D, Wolf R 2020 *Nat. Commun.* **11** 808
- [96] Cong I, Choi S, Lukin M D 2019 *Nat. Phys.* **15** 1273
- [97] Schuld M, Sweke R, Meyer J J 2021 *Phys. Rev. A* **103** 032430
- [98] Gili K, Sveistrys M, Ballance C 2023 *Phys. Rev. A* **107** 012406
- [99] Sharma K, Cerezo M, Cincio L, Coles P J 2022 *Phys. Rev. Lett.* **128** 180505
- [100] Bausch J 2020 *Adv. Neural Inf. Process. Syst.* (New York: Curran Associates, Inc.) p1368
- [101] Nguyen Q T, Schatzki L, Braccia P, Ragone M, Coles P J, Sauvage F, Larocca M, Cerezo M 2024 *PRX Quantum* **5** 020328
- [102] Zhou M G, Liu Z P, Yin H L, Li C L, Xu T K, Chen Z B 2023 *Research* **6** 0134
- [103] Wang L J, Lin J Y, Wu S 2022 *Phys. Rev. Res.* **4** 023058
- [104] Wang L J, Lin J Y, Wu S 2022 *Chin. Phys. Lett.* **39** 050301
- [105] Lin J Y, Li X Y, Shao Y H, Wang W, Wu S 2023 *Phys. Rev. A* **107** 042405
- [106] Abbas A, Sutter D, Zoufal C, Lucchi A, Figalli A, Woerner S 2021 *Nat. Comput. Sci.* **1** 403
- [107] Stokes J, Izaac J, Killoran N, Carleo G 2020 *Quantum* **4** 269
- [108] McClean J R, Boixo S, Smelyanskiy V N, Babbush R, Neven H 2018 *Nat. Commun.* **9** 4812
- [109] Cerezo M, Sone A, Volkoff T, Cincio L, Coles P J 2021 *Nat. Commun.* **12** 1791
- [110] Sannia A, Tacchino F, Tavernelli I, Giorgi G L, Zambrini R 2024 *Npj Quantum Inf.* **10** 81
- [111] Cerezo M, Verdon G, Huang H Y, Cincio L, Coles P J 2022 *Nat. Comput. Sci.* **2** 567
- [112] Pesah A, Cerezo M, Wang S, Volkoff T, Sornborger A T, Coles P J 2021 *Phys. Rev. X* **11** 041011
- [113] Pérez-Salinas A, Cervera-Lierta A, Gil-Fuster E, Latorre J I 2020 *Quantum* **4** 226
- [114] Kashif M, Al-Kuwari S 2024 *EPJ Quantum Technol.* **11** 4
- [115] Yao Y, Hasegawa Y 2025 *Phys. Rev. A* **111** 022426
- [116] Thanasilp S, Wang S, Cerezo M, Holmes Z 2024 *Nat. Commun.* **15** 5200
- [117] Pallavi G, Altalbe A, Kumar R P 2025 *Sci. Rep.* **15** 27103
- [118] Bhatia A S, Saggi M K, Kais S 2023 *J. Chem. Inf. Model.* **63** 6476
- [119] Lucas A 2014 *Front. Phys.* **2** 00005
- [120] Glover F, Kochenberger G, Du Y 2019 arXiv: 1811.11538 [cs]
- [121] Chen H, Kong X, Chong B, Qin G, Zhou X, Peng X, Du J 2011 *Phys. Rev. A* **83** 032314
- [122] Venturelli D, Marchand D J J, Rojo G 2016 arXiv: 1506.08479 [quant-ph]
- [123] Doga H, Raubenolt B, Cumbo F, Joshi J, DiFilippo F P, Qin J, Blankenberg D, Shehab O 2024 *J. Chem. Theory Comput.* **20** 3359
- [124] Yarkoni S, Raponi E, Bäck T, Schmitt S 2022 *Rep. Prog. Phys.* **85** 104001
- [125] Susa Y, Nishimori H 2021 *Phys. Rev. A* **103** 022619
- [126] Blekos K, Brand D, Ceschini A, Chou C H, Li R H, Pandya K, Summer A 2024 *Phys. Rep.* **1068** 1
- [127] Wang Z, Hadfield S, Jiang Z, Rieffel E G 2018 *Phys. Rev. A* **97** 022304
- [128] Zhou L, Wang S T, Choi S, Pichler H, Lukin M D 2020 *Phys. Rev. X* **10** 021067
- [129] Ruan Y, Marsh S, Xue X, Liu Z, Wang J 2020 *Comput. Mater. Contin.* **63** 1237
- [130] Azad U, Behera B K, Ahmed E A, Panigrahi P K, Farouk A 2023 *IEEE Trans. Intell. Transp. Syst.* **24** 7564
- [131] Mebtouche N E D, Sahnoune S 2024 *International Symposium on Quantum Sciences: Applications and Challenges* Alger ACad Sci & Tech, Algiers, Algeria, September 24–25, 2023 p152
- [132] Yao X W, Wang H, Liao Z, Chen M C, Pan J, Li J, Zhang K, Lin X, Wang Z, Luo Z, Zheng W, Li J, Zhao M, Peng X, Suter D 2017 *Phys. Rev. X* **7** 031041
- [133] Ji X, Liu Q, Huang S, Chen A, Wu S 2024 *Appl. Phys. Lett.* **125** 104002
- [134] Srivastava A K, Sharma S, Hussain S, Ghosh S, Sharma N 2025 *2025 3rd International Conference on Communication, Security, and Artificial Intelligence (ICCSAI)* Greater Noida, India, April 4–6, 2025 p225
- [135] Pandey S, Magri L, Arrigoni F, Golyanik V 2025 arXiv: 2504.13836 [cs]
- [136] Yang F F, Sasdelli M, Chin T J 2024 arXiv: 2409.02006 [cs]
- [137] Meli N K, Mannel F, Lellmann J 2022 *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* New Orleans, LA, USA, 2022 p519
- [138] Widdows D, Aboumrad W, Kim D, Ray S, Mei J 2024 *Künstl. Intell.* **38** 293
- [139] Meichanetzidis K, Gogioso S, de Felice G, Chiappori N, Toumi A, Coecke B 2021 *Electron. Proc. Theor. Comput. Sci.* **340** 213
- [140] Coecke B, Sadrzadeh M, Clark S 2010 arXiv: 1003.4394 [cs]
- [141] Yeung R, Kartsaklis D 2021 arXiv: 2105.07720 [cs]
- [142] Zeng W, Coecke B 2016 *Electron. Proc. Theor. Comput. Sci.* **221** 67
- [143] Meichanetzidis K, Toumi A, de Felice G, Coecke B 2023 *Quantum Mach. Intell.* **5** 10
- [144] Lorenz R, Pearson A, Meichanetzidis K, Kartsaklis D, Coecke B 2023 *J. Artif. Intell. Res.* **76** 1305
- [145] Zhao J, Yu W 2023 *Quantum Multi-Agent Reinforcement Learning as an Emerging AI Technology: A Survey and Future Directions*
- [146] Kölle M, Topp F, Phan T, Altmann P, Nüßlein J, Linnhoff-Popien C 2024 *Proceedings of the 16th International Conference on Agents and Artificial Intelligence* Rome, Italy, February 24–26, 2024 p71
- [147] Eisert J, Wilkens M, Lewenstein M 1999 *Phys. Rev. Lett.* **83** 3077
- [148] Khan F S, Solmeyer N, Balu R, Humble T 2018 *Quantum Inf. Process.* **17** 309
- [149] DeRieux A, Saad W 2025 arXiv: 2405.17486 [quant-ph]
- [150] Drăgan T A, Tandon A, Strobel C, Krauser J S, Lorenz J M 2024 arXiv: 2404.17499 [quant-ph]

SPECIAL TOPIC—Principles and applications of quantum optics

# Quantum artificial intelligence: a review of the bidirectional empowerment mechanisms and frontier progress in AI and quantum computing

YANG Junxia<sup>1)</sup> CAI Qizhi<sup>1)</sup> GUO Jinrong<sup>1)</sup> DENG Guangwei<sup>1)2)3)4)5)†</sup>1) (*Institute of Fundamental and Frontier Sciences, University of Electronic Science and Technology of China, Chengdu 610054, China*)2) (*Key Laboratory of Quantum Physics and Photonic Quantum Information, Ministry of Education, University of Electronic Science and Technology of China, Chengdu 610054, China*)3) (*CAS Key Laboratory of Quantum Information, University of Science and Technology of China, Hefei 230026, China*)4) (*Hefei National Laboratory, Hefei 230088, China*)5) (*Xinjiang Teacher's College, Urumqi 830043, China*)

( Received 30 December 2025; revised manuscript received 13 February 2026 )

## Abstract

As classical computing approaches its physical limits, quantum computing offers exponential computational advantages, yet the current noisy intermediate-scale quantum (NISQ) era is severely constrained by high error rates, decoherence, and control challenges. This has catalyzed quantum artificial intelligence (QAI), a synergistic and bidirectional interdisciplinary field. This review analyzes the “AI for Quantum” framework, where AI addresses quantum bottlenecks, and the “Quantum for AI” framework, where quantum computing enables novel computational paradigms for artificial intelligence.

The “AI for Quantum” framework elaborates the role of AI in addressing hardware bottlenecks. Specifically, this encompasses machine learning for autonomous device characterization, calibration, and high-fidelity readout, along with the development of advanced AI-based decoders and hardware-aware quantum error correction codes, as well as the optimization of quantum compilation.

The “Quantum for AI” framework surveys the progression from early algorithms such as HHL and QSVM to currently prevalent variational quantum algorithms and quantum neural networks. The primary obstacles are critically examined, including the barren plateau phenomenon and the exponential concentration of quantum kernels, together with their mitigation strategies. The review also covers advances in quantum optimization, such as quantum annealing and the quantum approximate optimization algorithm, and the emergence of advanced models like quantum natural language processing.

This bidirectional fusion represents a pivotal strategy for facilitating the transition from the NISQ era toward fault-tolerant computation and the development of next-generation, hybrid quantum-classical intelligent systems.

**Keywords:** quantum artificial intelligence, quantum computing, artificial intelligence

**DOI:** [10.7498/aps.75.20251792](https://doi.org/10.7498/aps.75.20251792)

**CSTR:** [32037.14.aps.75.20251792](https://cstr.cn/32037.14.aps.75.20251792)

† Corresponding author. E-mail: [gwdeng@uestc.edu.cn](mailto:gwdeng@uestc.edu.cn)

量子人工智能：人工智能与量子计算的双向赋能机制与前沿进展

杨君侠 蔡洪智 郭晋荣 邓光伟

**Quantum artificial intelligence: a review of the bidirectional empowerment mechanisms and frontier progress in AI and quantum computing**

YANG Junxia CAI Qizhi GUO Jinrong DENG Guangwei

引用信息 Citation: *Acta Physica Sinica*, 75, 100603 (2026) DOI: 10.7498/aps.75.20251792

CSTR: 32037.14.aps.75.20251792

在线阅读 View online: <https://doi.org/10.7498/aps.75.20251792>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

人工智能赋能量子通信与量子传感系统

Research progress of artificial intelligence empowered quantum communication and quantum sensing systems

物理学报. 2025, 74(12): 120301 <https://doi.org/10.7498/aps.74.20250322>

“机器微纳光学科学家”：人工智能在微纳光学设计的应用与发展

“Machine micro/nano optics scientist” : Application and development of artificial intelligence in micro/nano optical design

物理学报. 2023, 72(11): 114204 <https://doi.org/10.7498/aps.72.20230208>

基于人工智能算法的宽稳区大模场纳秒激光产生

Generation of nano second laser with wide stable region and large mode field based on artificial intelligence algorithm

物理学报. 2025, 74(16): 164206 <https://doi.org/10.7498/aps.74.20250519>

基于去噪概率扩散模型的蝠鲮流场智能化预测

Intelligent prediction of manta ray flow field based on a denoising probabilistic diffusion model

物理学报. 2025, 74(10): 104701 <https://doi.org/10.7498/aps.74.20241499>

面向量子计算的拓扑超导体材料、物理和器件研究

Research progress of material, physics, and device of topological superconductors for quantum computing

物理学报. 2022, 71(16): 160302 <https://doi.org/10.7498/aps.71.20220596>

量子存储式量子计算机与无噪声光子回波

“Quantum memory” quantum computers and noiseless photon echoes

物理学报. 2022, 71(7): 070305 <https://doi.org/10.7498/aps.71.20212245>