

融合经典与量子：量子机器学习技术现状与发展挑战

李阳阳 邓禹 刘煜森 戚政雅 刘蕴恩 尚荣华 焦李成

(西安电子科技大学人工智能学院,智能感知与图像理解教育部重点实验室,智能感知与计算国际联合研究中心,陕西省量子信息协同创新中心,西安市类脑感知与认知国际科技合作基地 710071)

一、引言

在数字化进程持续加速的当下,计算技术作为驱动科技演进的核心支撑,正以前所未有的规模与速度深刻重塑社会各领域。尤其是人工智能模型日趋复杂、数据规模不断增长,促使计算资源的需求呈指数式膨胀。这一趋势直接推升了全球数据中心的能耗水平。据能源相关机构预测,部分国家的数据中心在全国电力消耗中的占比将于短期内出现显著上升,给能源基础设施与碳排放控制带来深层挑战^[1-3]。此背景下,传统计算范式已显瓶颈,行业亟需一种兼顾算力提升与能效控制的新型计算架构,以支撑未来AI的可持续发展。

量子计算作为一种基于量子力学基本原理的前沿技术,正在构建一种与经典计算截然不同的计算模式。传统计算机以“比特”为基本信息单位,状态仅为0或1;而量子计算机以“量子比特”(qubit)作为计算载体,其状态可同时处于0与1的叠加态,并能通过量子纠缠在比特间建立远非经典所能实现的关联关系。这些独特的物理性质使量子计算在某些特定问题上具备并行性极强、计算复杂度显著降低的潜力,尤其在大规模优化、线性代数处理、概率分布建模等任务中展现出天然优势。同时,相较于传统计算平台,量子计算理论上可在能耗控制方面实现更高的效率,这为构建“绿色智能芯片”提供了技术路径,也使其成为推动未来AI基础架构转型的重要候选技术^[4]。

尽管当前量子计算机尚处于发展初期,硬件规模与稳定性仍面临诸多技术挑战,但其与人工智能

的深度融合已成为学术与产业界重点关注的研究方向,即“量子人工智能”(Quantum AI)。从现有趋势来看,可预期的计算架构将呈现“量子-经典混合”形态,其中经典计算机依然承担通用任务处理,而量子处理器将以加速器形式嵌入(QPU),在机器学习中承担求解复杂优化函数、建立高维概率模型等计算瓶颈环节^[5]。此混合模式不仅可充分发挥现有计算资源效能,还将渐进式引入量子计算的新能力,在“增强而非替代”的思路下助力AI系统性能实现跃升。

更进一步,量子计算的引入不止意味着处理速度的提升,更意味着人工智能的表达方式和推理机制将发生范式级变革:例如支持更高维度的特征映射、更复杂的数据关联建模,甚至可能启发出区别于经典机器学习的新一代算法体系。从能效提升到模型结构重塑,量子计算为当前困于摩尔定律约束的算力体系开辟出一条潜在突破路径。它不仅回应了算力增长与能耗控制之间的结构性矛盾,也为理解复杂系统、探索科学极限提供了新的理论与工具支撑。因此,量子人工智能正逐步从前沿探索迈向工程实践,成为未来计算技术体系演进中的关键增长点,预示着一个更高效、更智能、更绿色的计算新纪元的到来。

二、经典机器学习与量子计算概念

在上一节我们讨论了算力瓶颈与能效挑战正在驱动计算范式的革新,其中量子计算作为一种以物理原理为底层基础的新型技术,正在与人工智能

加速融合,形成“量子人工智能”的发展热点。要理解这种融合的技术路径与设计要点,首先需要对经典机器学习的基本框架与量子计算的核心原理建立清晰的知识结构。本节将分别介绍两者的核心概念、表示机制与运算逻辑,为后续探讨量子机器学习方法打下基础。

2.1 经典机器学习

经典机器学习是一种基于数据驱动的建模方法,按照任务设定的不同,通常可分为三大类:监督学习、无监督学习与强化学习。三者数据组织形式、优化目标以及学习流程方面存在显著差异^[6]。

监督学习依赖带标签的数据样本,模型通过学习输入与标签之间的映射关系来完成预测任务。例如,在手写数字识别中,图像作为输入特征,对应数字则为标签。模型需不断调整参数以最小化预测输出与真实标签之间的误差,从而提升泛化能力。该学习过程依赖“监督信号”,即标签数据的指导,因此称为监督学习。

无监督学习则处理无标签数据,重点在于发现数据内部的潜在结构与关联。例如,将一组手写图像依据图案相似性进行自动聚类,无需预先标注类别,而是通过计算样本间的距离或相似度,构建数据的聚合结构。无监督学习常用于数据降维、聚类分析与异常检测等任务,强调结构建模而非精准预测。

强化学习适用于序列决策问题,模型在与环境交互过程中通过试错探索出最优策略。它通常引入奖惩机制,根据不同状态一行动组合所获得的回报反馈来更新策略,目标是最大化长期回报。例如,围棋智能体如AlphaGo,通过数百万次对弈积累经验,最终形成在不同局面下的高质量决策。强化学习强调长期回报与策略优化,与监督学习的静态映射不同,更强调动态优化与策略迭代。

这三类学习范式构成了经典机器学习的基础框架,各自对应不同的数据场景与任务类型。在后续构建量子版本时,也需分别考虑其对应的量子数据编码方法、参数优化机制与测量逻辑。

2.2 量子计算概念

量子叠加:量子计算是建立在量子力学原理之上的新型计算模式,其核心差异体现在信息表示与计算原语的根本变化。量子比特作为基本信息单元,可同时处于多个状态的叠加态,从而在状态空间中提供比经典比特更为丰富的表达能力。

以最基本的自旋1/2体系电子自旋为例,电子自旋有两个本征态(一般称为“自旋向上”和“自旋向下”),而电子可以处于这两个本征态按照任意比例叠加的叠加态。一般可以用Dirac符号

$$|\psi\rangle = a|0\rangle + b|1\rangle \quad (1)$$

或列向量

$$\begin{pmatrix} a \\ b \end{pmatrix} = a \begin{pmatrix} 1 \\ 0 \end{pmatrix} + b \begin{pmatrix} 0 \\ 1 \end{pmatrix} \quad (2)$$

来表示以 a 和 b 作为比例系数的叠加态。

在对电子自旋进行测量的时候,电子会根据两个本征态的占比来以某种几率出现在某一本征态,即测量使得原本处于叠加态的电子“坍塌”到某一个本征态。如果电子处于 $|\psi\rangle = a|0\rangle + b|1\rangle$ 的叠加态,那么测量将会有 $\frac{|a|^2}{|a|^2 + |b|^2}$ 的几率测得自旋向上, $\frac{|b|^2}{|a|^2 + |b|^2}$ 的几率测得自旋向下。

类似地,量子比特相比于经典比特(只有 $|0\rangle$ 和 $|1\rangle$ 两种状态)有无数种状态($|0\rangle$ 和 $|1\rangle$ 的任意叠加)。量子计算就是利用了量子比特的这个特点来实现并行计算。两个量子比特的量子态可以用类似的方式表示为:

$$a|00\rangle + b|01\rangle + c|10\rangle + d|11\rangle = a \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix} + b \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \end{pmatrix} + c \begin{pmatrix} 0 \\ 0 \\ 1 \\ 0 \end{pmatrix} + d \begin{pmatrix} 0 \\ 0 \\ 0 \\ 1 \end{pmatrix} = \begin{pmatrix} a \\ b \\ c \\ d \end{pmatrix} \quad (3)$$

量子比特的物理实现有多种方式,如IBM公司的超导量子比特,IonQ公司的离子阱量子比特等。

量子纠缠:进一步地,量子纠缠描述了多个量

子比特之间无法因式分解的非经典关联。纠缠态中的一方被测量后,另一方的状态随之变化,即使两者在空间上相距甚远。

量子纠缠的概念最早来自爱因斯坦提出的EPR佯谬,是量子信息处理中的独特资源,在量子通信与量子算法中扮演核心角色。假设两个独立的自旋1/2体系分别处于 $a|0\rangle + b|1\rangle$ 和 $c|0\rangle + d|1\rangle$ 的状态,那么整个体系的量子态为

$$(a|0\rangle + b|1\rangle) \otimes (c|0\rangle + d|1\rangle) = ac|00\rangle + ad|01\rangle + bc|10\rangle + bd|11\rangle \quad (4)$$

如果对体系1进行测量并且得到 $|0\rangle$,那么整体的量子态变为:

$$c|00\rangle + d|01\rangle = |0\rangle \otimes (c|0\rangle + d|1\rangle) \quad (5)$$

可以看出体系2的量子态不受体系1测量结果的影响。这也符合直觉,因为两个体系相互独立。

然而,两个自旋1/2体系还可以处在诸如 $a|00\rangle + b|11\rangle$ 的“纠缠”态中。此时体系1的测量结果会影响体系2的量子态。这种多体系之间的纠缠现象是量子系统的独有特征。

量子门:计算操作由量子门完成,它们是作用于量子态的幺正变换,和经典电路中的逻辑门类似,量子逻辑门(简称为量子门)的作用是操纵量子比特的量子态。和经典门不同的是,量子门都是可逆的,即可以从量子门的输出推导出量子门的输入。相反地,经典逻辑门中的“或门”就没有这个特点。

表1列举了一些基础的量子门。量子门一般可以用矩阵来表示。例如Hadamard门作用在 $|0\rangle = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ 态后得到

$$\frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 \\ 0 \end{pmatrix} + \frac{1}{\sqrt{2}} \begin{pmatrix} 0 \\ 1 \end{pmatrix} \quad (6)$$

即Hadamard将原本的 $|0\rangle$ 态变为了 $|0\rangle$ 和 $|1\rangle$ 的叠加态。CNOT门作用在两个量子比特上,因此维数为4。

量子门的物理实现一般是通过激光、磁场等手

表1 量子门及其属性

| 量子门 | 矩阵表示 | 作用 |
|----------|--|---------------------------------|
| Hadamard | $\frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$ | 通过变换量子比特的量子态来产生叠加态 |
| CNOT | $\begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{pmatrix}$ | 如果控制量子比特为 $ 1\rangle$,翻转目标量子比特 |
| Pauli-X | $\begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$ | 翻转量子比特 |
| Pauli-Y | $\begin{pmatrix} 0 & -i \\ i & 0 \end{pmatrix}$ | 将量子比特沿Y轴旋转180度 |
| Pauli-Z | $\begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}$ | 翻转量子比特的相位 |
| Rx | $\begin{pmatrix} \cos \frac{\theta}{2} & -i \sin \frac{\theta}{2} \\ -i \sin \frac{\theta}{2} & \cos \frac{\theta}{2} \end{pmatrix}$ | 将量子比特沿X轴旋转 |
| Ry | $\begin{pmatrix} \cos \frac{\theta}{2} & -\sin \frac{\theta}{2} \\ \sin \frac{\theta}{2} & \cos \frac{\theta}{2} \end{pmatrix}$ | 将量子比特沿Y轴旋转 |
| Rz | $\begin{pmatrix} e^{-i\frac{\theta}{2}} & 0 \\ 0 & e^{i\frac{\theta}{2}} \end{pmatrix}$ | 将量子比特沿Z轴旋转 |

段对物理量子比特进行操纵。

三、数据编码与量子变分线路

量子机器学习的核心在于搭建经典数据与量子计算之间的连接桥梁,并借助可编程量子架构实现计算加速。首先,量子数据编码技术用于将经典信息转换为可操作的量子态,其编码效率与保真度在很大程度上决定了计算潜力的上限;其次,变分量子电路通过参数化量子门序列构建可调节的量子计算模块,成为当前含噪声中等规模设备(NISQ)的主要载体;继而,量子神经网络(Quantum Neural Network, QNN)在此基础上构建更复杂的架构,在特征提取、时序建模与生成式学习等应用中展现出颠覆性的潜力^[7];此外,诸如量子退火的算法利用量子物理特性突破组合优化中的瓶颈^[8]。上述模块共同构成“数据输入→量子处理→结果输出”的完整技术链条,其协同发展正引领量子机器学习逐步从理论探索走向实际应用^[9]。下文将依次深入解析各技术模块的原理基础、发展路径与研究突破。

3.1 量子数据编码

量子数据编码的目的是将经典信息转化为可在量子电路中操作的量子态,目前主要采用三种方法对经典数据进行编码(如图1所示)。

量子角度编码(Angle Encoding)是一种将经典数据直接映射为量子比特旋转角度的编码方式,其数学本质是通过单量子比特门的操作完成从经典数据到量子态的转换^[10]。给定 d 维经典向量 $x = (x_1, x_2, \dots, x_d)$, 其基础编码形式为:

$$|\psi_x\rangle = \bigotimes_{j=1}^d R_\sigma(\theta_j)|0\rangle \quad (7)$$

其中 $R_\sigma(\theta_j) = e^{-i\theta_j\sigma}$ 是作用于泡利算符 $\sigma \in \{X, Y, Z\}$ 的旋转门, $\theta_j = f(x_j)$ 为特征值至旋转角度的映射函数。该编码方式的优势在于其资源消耗呈线性增长(d 维数据需 d 个量子比特),电路深度低(仅使用单比特门),使其在NISQ环境下具有极高的实用性。

振幅编码(Amplitude Encoding)是量子机器学习理论表现最优的数据编码方法,其核心思想是将经典数据嵌入到量子态的振幅系数中。设有归一化的 N 维经典向量 $x = (x_1, x_2, \dots, x_N)$, 其量子态表示如下:

$$|\psi_x\rangle = \frac{1}{\|x\|_2} \sum_{i=0}^{N-1} x_i |i\rangle, \quad \|x\|_2 = \sqrt{\sum_{i=0}^{N-1} x_i^2} \quad (8)$$

其中归一化因子 $\|x\|_2$ 保证量子态的归一性;

每个基矢的振幅由向量元素与该因子的比值给出,其平方即为测量得到该基态的概率。此方法利用量子叠加原理,仅需个 $n = \log_2 N$ 量子比特即可表示 N 维数据,在量子机器学习、搜索与数据压缩等领域具有广泛应用。尽管制备任意振幅的高精度量子态在实验上仍存在技术挑战,但其指数级的存储效率为处理高维数据提供了独特优势。

量子哈密顿编码是一种将经典问题(如优化问题、约束满足问题)中的目标函数或约束条件转化为量子系统哈密顿量的方法。该方法的核心是构造一个哈密顿量 H , 使其本征态对应问题的候选解,而本征值则映射为解的能量或目标函数值。通过量子算法(如量子绝热演化)寻找 H 的基态即可获得最优解^[11]。例如,在组合优化问题中,哈密顿量可表示为约束项与目标项之和:

$$H = H_{\text{constraint}} + H_{\text{objective}} \quad (9)$$

其中约束项 $H_{\text{constraint}} = \sum_k c_k P_k$ 用于确保解满足问题要求(c_k 为系数, P_k 为泡利算符组合),目标项 $H_{\text{objective}} = \sum_i w_i Q_i$ 量化解的优劣(w_i 为权重, Q_i 为泡利算符组合)。

3.2 变分量子电路

变分量子算法(Variational Quantum Algorithm, VQA)是一种经典与量子混合的计算框架,其核心流程是通过迭代优化量子线路中的可调参数,不断逼近目标函数的最优值,最终以量子态或可观测量

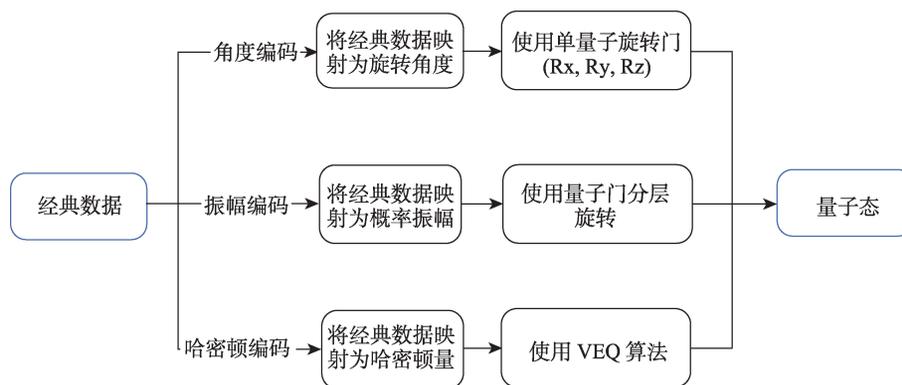


图1 量子编码方式

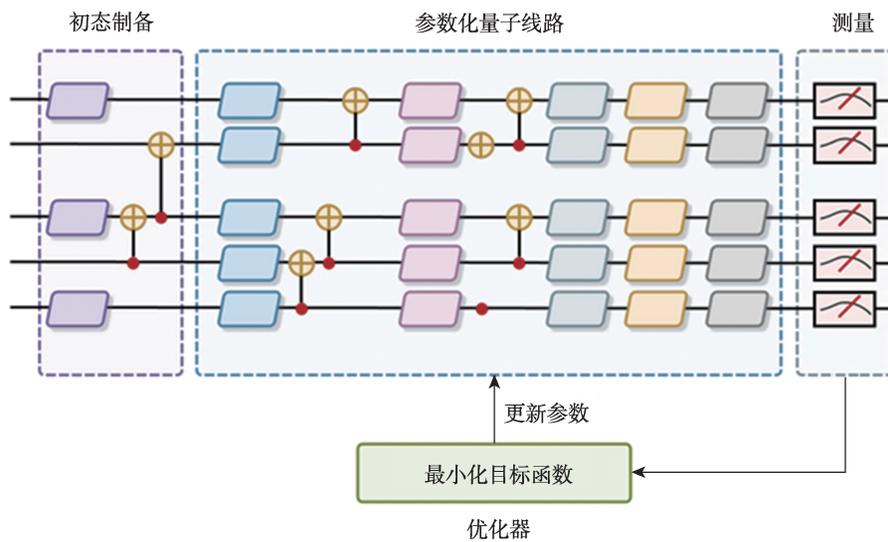


图2 变分量子算法

的期望值作为问题解^[12](参考图2)。

其实现步骤包括:初始化量子态(通常为 $|0\rangle^{\otimes n}$, 特殊算法如 QAOA 使用 $|+\rangle^{\otimes n}$);构建含随机参数的初始量子线路;在预设可观测量基础上进行量子测量以获得目标函数的当前数值;利用经典优化器不断更新线路参数以降低该值;最终使用最优参数执行量子线路以输出解。该算法的三大关键组成要素是目标函数的构建、参数化量子线路的结构设计,以及经典优化器的选择^[13]。

3.3 量子神经网络

量子神经网络(Quantum Neural Network, QNN)是一种融合量子计算机制与经典神经网络理念的新型计算模型,其核心在于利用量子态的叠加性、纠缠性以及量子门的幺正性,构建具有潜在量子优势的学习结构。与经典神经网络依赖神经元之间权重传递的方式不同,量子神经网络通常以参数化量子线路(Parameterized Quantum Circuit, PQC)为基本模块,通过可调节的量子门(如旋转门、纠缠门)实现对输入数据的编码、特征提取和态变换,再借助测量过程获得经典输出,并结合经典优化器对参数进行迭代更新以最小化损失函数。

从结构角度来看,量子神经网络的基本组成包

括量子神经元、量子连接权重与量子激活函数。量子神经元支持多参数联合优化;量子权重通过量子纠缠实现信息共享;量子激活函数则通过态变换实现非线性处理。输入数据可通过振幅编码或角度编码等方式映射至量子态;中间层以量子门组合构建高维特征空间的非线性变换,其表达能力可随量子比特数量指数提升;最终输出层通过对量子态的测量获得任务所需的经典量(如分类结果或回归值)。

此类架构在处理高维数据场景(如量子化学分子结构、大规模图像分析)中展现出多项式甚至指数级加速的潜力,在量子机器学习、优化和图模式识别等领域具有广阔前景。当前主要的量子神经网络模型包括基础量子神经网络(QNN)、量子卷积神经网络(Quantum Convolution Neural Network, QCNN)^[14](参考图3)等。

当前的研究重点包括:提升可训练性(如缓解“平坦高原”问题)^[15]、扩展适配的量子硬件平台(如超导量子芯片、离子阱系统),以及开发与经典神经网络融合的混合架构(如量子-经典混合深度学习)^[16-18]。尽管受限于当前硬件的噪声与比特数,量子神经网络的实际性能仍处于逐步验证阶段,但其为突破传统计算瓶颈、实现高效智能学习提供了崭新路径,已成为量子信息科学与人工智能交叉领域的研究

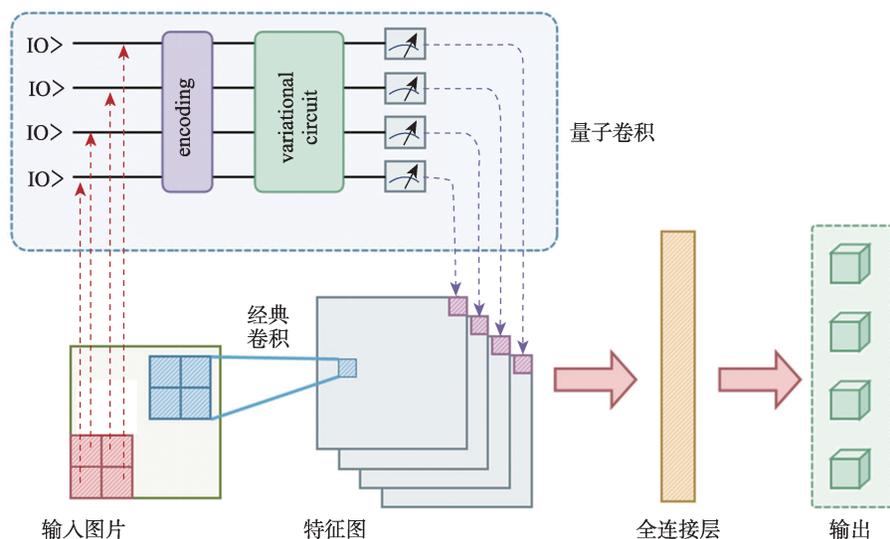


图3 量子卷积神经网络 QCNN

热点之一。

3.4 量子退火算法

量子退火算法是一种利用量子隧穿效应和量子涨落机制高效求解组合优化问题的方法^[19,20]。其核心思想是将优化任务转化为伊辛模型(Ising Model)下的哈密顿量基态搜索,其中每个自旋变量代表一个比特状态(± 1),目标函数被映射为哈密顿量的能量最小化问题。

算法流程包括:首先初始化量子系统为横向磁场哈密顿量的基态,随后缓慢调节量子参量(如逐步削弱量子隧穿强度、增强目标哈密顿量的权重),借助量子动力学演化过程中的隧穿效应,使系统成功跨越势能障碍,最终趋近于经典优化问题的最优或近优解。目前,该算法已在如 D-Wave 等公司研制的专用量子计算机上投入实际应用,覆盖物流路径规划、金融风险评估、药物分子构型优化以及机器学习中的训练难题(例如量子玻尔兹曼机的权重调优)。其核心优势在于具备规避传统优化算法易陷入的局部极小值陷阱的能力,尤其适配 NP 难问题。但其实际性能仍受限于量子比特连通性、噪声干扰及问题映射精度等因素,是量子计算在优化问题实用化进程中极具潜力的关键技术路径。

四、相关工作与研究现状

下面简要回顾量子机器学习的发展脉络,并重点阐述当前研究与应用的现状。整体上,量子机器学习包含两条相互补充的路径:一条是基于量子计算模型与量子硬件的“量子算法”;另一条是将量子物理思想与经典智能优化融合的“类量子算法(量子启发式)”(参考图4)。前者强调在量子硬件上实现理论可证明的加速或表达优势,后者在经典计算平台上通过“量子式”表示与机制提升搜索与学习能力。在当前硬件仍处于 NISQ 阶段的条件下,这两条路径共同推动了理论、算法与应用的协同进展。

4.1 量子算法:从理论奠基到 NISQ 时代的混合范式

量子算法的探索始于 1982 年费曼提出“用量子计算机模拟量子系统”的大胆设想,犹如打开了一扇通往微观世界的新窗^[21]。随后,量子算法的早期阶段(约 1985~1994)以“展示量子潜在优势”为主要目标:1985 年,Deutsch 在量子图灵机模型中首次利用叠加与干涉描绘出量子计算框架的雏形^[22]。1992 年,Deutsch-Jozsa 算法以指数级速度验证了量子并行性的潜力^[23]。1993 年,Aharonov 等人提出量

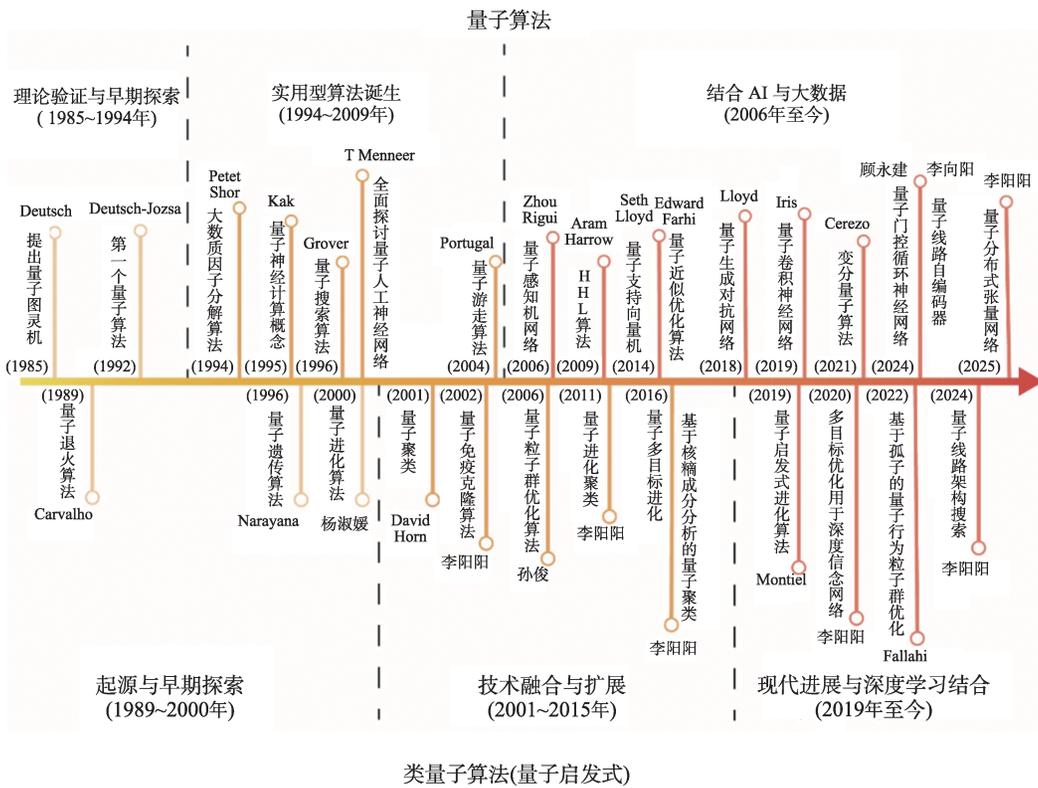


图4 研究历程

子随机游走,为后续游走算法奠定了理论基础^[24]。1994年,Simon算法首次展示了多项式时间内解决特定问题的能力^[25]。这个阶段的算法多用于“概念性示范”,实用价值有限,但清晰地刻画出量子并行性、干涉与测量对计算复杂度的影响路径。

第二阶段(约1994~2009年)转向“面向重要应用问题的量子算法”。里程碑是1994年Shor的大整数质因数分解的量子算法,它把经典上被视为难题的任务降到多项式时间,引发了对公钥密码体系安全性的系统性反思,并使量子傅里叶变换成为算法设计中的核心工具^[26]。1996年,Grover的无序搜索实现平方加速,形成“振幅放大”这一通用技巧^[27]。标准量子电路模型在此期间被系统化,算法与硬件抽象层面逐步统一^[10];与机器学习相关的早期探索(如量子神经计算的设想、量子小波变换、量子随机游走在图算法中的推广)开始出现,并逐步从“思想启发”走向“可实现框架”的构造^[28-30]。

第三阶段(2006年至今)聚焦“与大数据与机器

学习的结合”及“在NISQ设备上的可实现性”。自2006年起,随着NISQ走到台前,量子算法与机器学习的深度融合成为主舞台。2006年,Zhou等人提出量子感知器网络,将量子态旋转视为“调色盘”进行特征编码^[31]。2009年,Harrow-Hassidim-Lloyd(HHL)算法为线性方程组求解开辟了多项式时间通道^[32]。2012年,Clader等人将预条件技术引入量子最小二乘,首次实现量子回归分析^[33]。2014年,Lloyd团队推出量子支持向量机^[34],Farhi等人提出QAOA^[11],分别在高维分类与组合优化领域取得突破。

2016年Kapoor提出量子特征映射方法,将输入数据编码为量子门序列,通过测量量子态实现分类^[13]。2018年,Lloyd等人提出量子生成对抗网络(QGAN),构建基于量子神经网络的生成对抗学习框架,用于生成目标分布的量子态^[35,36];2019年,Carlos等人在HHL算法基础上,提出适用于NISQ设备的量子-经典混合线性系统求解方法^[37];同年,

Iris 等人受经典卷积神经网络的启发,设计用于量子相位识别与纠错的纯量子卷积网络^[14]。2020年,Beer 等人提出一种量子模拟的深度神经网络训练方法^[38]。2021年,Pesah 团队构建可规避梯度消失问题的量子神经网络架构,理论证明部分量子网络不受贫瘠高原影响,提升训练稳定性^[15]。2022年,Chen 等人提出适用于高能物理数据分析的量子-经典混合 QCNN,支持高达 30×30 维输入;架构通用性强,适用于图像分类以外任务^[39]。2024年,李向阳与 Haiyue Zhang 提出量子电路自动编码器模型,首次系统定义无损压缩条件与保真度界限;显著缓解去极化噪声^[40]。紧接着,顾永建团队推出构建了带有门控机制的量子循环神经网络架构^[41]。2025年,李阳阳团队首创将量子电路拆分技术应用于多模态情感分析任务,将量子资源使用从 n 降至 $n/2 + 1$,缓解 NISQ 设备量子位稀缺瓶颈;同时构建分布式量子集群 workflow,提升计算效率与模型扩展性^[42]。

4.2 类量子算法(量子启发式):物理直觉赋能的工程型优化

与此并行,类量子启发式算法在大规模优化与智能计算领域同样异彩纷呈。类量子算法并不依赖量子硬件运行,而是把量子态、叠加、隧穿、测不准等物理概念抽象为概率表示、搜索跳变与全局探索机制,从而提升经典智能算法的效果。1989年,量子退火与随机优化算法利用量子隧道效应跳出局部极值,提升大规模优化效率^[43]。1996年,Narayanan 等人将量子叠加思想引入遗传算法,开启了量子遗传的发展^[44]。2000年,Kadowaki 和 Nishimori 在 15 城旅行商问题上演示了量子退火优于经典退火的性能^[19]。此后,Han 的量子进化算法^[45,46]、Horn 的量子聚类^[47]、孙俊等人的粒子群优化算法 QPSO^[48]与李阳阳团队的量子免疫克隆算法 QICA^[49],以及 2019 年 Montiel 的蚂蚁启发进化^[50]和 2022 年基于孤子概念的 QPSO 变体^[51]相继出现,不断拓展优化新路径。2024 年,李阳阳团队提出的 EQNAS^[52]用于遥感目标分类,自动为纯量子神经网络

进行架构搜索(无需人类经验);首次引入 I 门作“跳跃连接”以降参并缓解深度依赖,针对门选择不确定与规模扩展导致的部署难与精度瓶颈给出改进,搜索结果可在量子环境端到端运行,无需经典辅助。

虽然量子启发式算法和纯量子算法都旨在突破经典计算的局限,但是二者在硬件依赖、性能目标和使用场景方面存在显著差异。在硬件方面,量子启发式算法不依赖于量子硬件,它是将量子相关的物理概念进行抽象而可以在经典计算机上进行。与之相反的是纯量子算法严格依赖量子硬件运行;在性能目标方面,量子启发式算法旨在解决当前大规模优化和智能计算的问题,提高现有智能计算的性能极限。而纯量子算法希望通过指数级加速解决经典计算机难以触及的根本性计算难题,但此类算法的稳定性和可扩展性十分受量子硬件发展的限制;在适用场景方面,量子启发式算法不受限于量子硬件,在经典硬件上就可以提升解决当前大规模经典优化和智能计算问题算法的性能。纯量子算法适用于解决特定领域的、具有指数级计算难度的瓶颈问题和自然界量子系统的模拟,但具体应用受到当前量子硬件的制约。

五、挑战与展望

量子人工智能的发展正处于由理论走向实用的关键阶段,其潜力虽已被广泛认可,但从实验验证到工程落地仍面临多维挑战。硬件层面,目前量子计算仍以 NISQ 设备为主,量子比特的数量、保真度、相干时间和门操作精度均尚未达到支持大规模计算的要求。系统的稳定性和扩展性仍受限于退相干与控制精度,量子误差纠正虽提供了解决路径,却需大量物理比特与复杂的控制机制,带来额外能耗与技术成本。因此,当前算力尚无法完全支撑 AI 模型的通用推理与训练任务。

算法方面,变分量子算法、量子支持向量机、量子图模型等已初步展现其在优化与概率建模中的优势,但其适用性和可训练性仍受限。在大模型场

景下,参数空间高维、优化目标复杂,现有量子算法难以稳定收敛,且面临梯度消失、结构不匹配等问题。同时,数据加载仍是一大瓶颈,缺乏高效的量子随机访问存储机制(如QRAM)限制了对真实大数据的表达与调用,使得模型训练过程中量子速度优势难以有效发挥。

在此背景下,量子大模型作为量子人工智能的下一阶段演进形态,逐步成为研究焦点。其核心设想是将量子计算能力嵌入到基础大模型的关键模块中,重构高维优化、表示学习与生成机制。例如,在语言模型中引入量子态空间可提升语义嵌入的维度与结构复杂度;利用量子纠缠机制可增强跨模态特征的融合表达;通过量子退火与变分优化算法可加速训练收敛过程并降低能耗。此外,也有研究探索量子原生模型架构——直接以量子态为输入输出,从底层构建具备新型学习能力的模型体系。

然而,量子大模型的构建仍面临工程实现的挑战。硬件资源尚不支持大规模多层结构的部署,量子电路深度和宽度受限;编程工具链尚不成熟,开发门槛高;验证与评估框架尚未建立,难以量化其性能、能效与泛化能力。此外,如何在经典与量子之间进行高效协同,构建量子辅助训练流程与推理接口,仍有待系统化解决。

展望未来,可行路径将以量子-经典混合架构为起点,优先在组合优化、高维概率推断、特征重构等场景引入量子处理器作为协处理单元,逐步验证其对模型性能的实际提升。同时应构建标准化的评测体系,包括精度指标、训练时长、能效比与碳足迹等维度,以推动技术向产业化迈进。在长期目标上,量子大模型或将成为新一代AI认知架构的基础构件,赋予模型更强的表达力、泛化能力与能耗控制能力。

总体而言,量子人工智能的发展应坚持硬件—算法—应用的协同设计原则,在保持理性、逐步推进的基础上探索真正具备量子原生优势的AI模型体系。量子计算不仅是算力跃迁的路径,更是AI范

式转变的催化器,它为我们提供了突破经典限制、重构智能未来的新可能。

* 基金项目:国家自然科学基金(62476209, 62576260);
陕西省重点研发计划(2024CY2-GJHX-18)

参考文献

- [1] Mämmelä O, Majanen M, Basmadjian R, et al. Energy-aware job scheduler for high-performance computing[J]. *Computer Science - Research and Development*, 2012, 27(4): 265-275.
- [2] Technological forecasting of supercomputer development: The March to Exascale computing[J]. *Omega*, 2015, 51: 128-135.
- [3] Towards EXtreme scale technologies and accelerators for euROhpc hw/Sw supercomputing applications for exascale: The TEXTAROSSA approach[J]. *Microprocessors and Microsystems*, 2022, 95: 104679.
- [4] Jaschke D, Montangero S. Is quantum computing green? An estimate for an energy-efficiency quantum advantage[J]. *Quantum Science and Technology*, 2023, 8(2): 025001.
- [5] Suchara M, Alexeev Y, Chong F, et al. Hybrid quantum-classical computing architectures[C]//*Proceedings of the 3rd International Workshop on Post-Moore Era Supercomputing*, 2018.
- [6] Emmert-Streib F, Dehmer M. Taxonomy of machine learning paradigms: A data-centric perspective[J]. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2022, 12(5): e1470.
- [7] Safari A, Badamchizadeh M A. NeuroQuMan: quantum neural network-based consumer reaction time demand response predictive management[J]. *Neural Computing and Applications*, 2024, 36(30): 19121-19138.
- [8] Orito T, Kuno Y, Ichinose I. Strong and weak symmetries and their spontaneous symmetry breaking in mixed states emerging from the quantum Ising model under multiple decoherence[J]. *Phys. Rev. B*, 2025, 111(5): 054106.
- [9] Melnikov A, Kordzanganeh M, Alodjants A, et al. Quantum Machine Learning: from physics to software engineering[J]. *Advances in Physics: X*, 2023, 8(1): 2165452.
- [10] PAUL T. Quantum computation and quantum information[J]. *Mathematical Structures in Computer Science*, 2007, 17(6): 1115-1115.
- [11] Farhi E, Goldstone J, Gutmann S. A Quantum Approximate Optimization Algorithm[A]. arXiv, 2014.
- [12] Cerezo M, Arrasmith A, Babbush R, et al. Variational quantum algorithms[J]. *Nature Reviews Physics*, 2021, 3(9): 625-644.
- [13] Kapoor A, Wiebe N, Svore K. Quantum Perceptron Models[C]//*Advances in Neural Information Processing Systems: Vol. 29*. Curran Associates, Inc., 2016.
- [14] Cong I, Choi S, Lukin M D. Quantum convolutional neural networks[J]. *Nature Physics*, 2019, 15(12): 1273-1278.
- [15] Pesah A, Cerezo M, Wang S, et al. Absence of Barren Plateaus in Quantum Convolutional Neural Networks[J]. *Physical Review X*,

- 2021, 11(4): 041011.
- [16] Suzuki T, Hasebe T, Miyazaki T. Quantum support vector machines for classification and regression on a trapped-ion quantum computer[J]. *Quantum Machine Intelligence*, 2024, 6(1): 31.
- [17] Shi M, Situ H, Zhang C. Hybrid quantum neural network structures for image multi-classification[J]. *Physica Scripta*, 2024, 99(5): 056012.
- [18] Gandhudi M, P.J.A.A, Fiore U, et al. Explainable hybrid quantum neural networks for analyzing the influence of tweets on stock price prediction[J]. *Computers and Electrical Engineering*, 2024, 118: 109302.
- [19] Kadowaki T, Nishimori H. Quantum annealing in the transverse Ising model[J]. *Physical Review E*, 1998, 58(5): 5355-5363.
- [20] Zheng Q, Yu M, Zhu P, et al. Solving the subset sum problem by the quantum Ising model with variational quantum optimization based on conditional values at risk[J]. *Science China Physics, Mechanics & Astronomy*, 2024, 67(8): 280311.
- [21] Feynman R P. Simulating physics with computers[J]. *International Journal of Theoretical Physics*, 1982, 21(6): 467-488.
- [22] Deutsch D. Quantum theory, the Church-Turing principle and the universal quantum computer[J]. *Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences*, 1985, 400(1818): 97-117.
- [23] Deutsch D, Jozsa R. Rapid solution of problems by quantum computation[J]. *Proceedings of the Royal Society of London. Series A: Mathematical and Physical Sciences*, 1992, 439(1907): 553-558.
- [24] Aharonov Y, Davidovich L, Zagury N. Quantum random walks [J]. *Physical Review A*, 1993, 48(2): 1687.
- [25] Simon D R. On the power of quantum computation[J]. *SIAM journal on computing*, 1997, 26(5): 1474-1483.
- [26] Shor P W. Algorithms for quantum computation: discrete logarithms and factoring[C]//*Proceedings 35th Annual Symposium on Foundations of Computer Science*. 1994: 124-134.
- [27] Grover L K. A fast quantum mechanical algorithm for database search[C]//*Proceedings of the twenty-eighth annual ACM symposium on Theory of Computing*. New York, NY, USA: Association for Computing Machinery, 1996: 212-219.
- [28] Hoyer P. Efficient quantum transforms[J]. *arXiv preprint quant-ph/9702028*, 1997.
- [29] Narayanan A, Menneer T. Quantum artificial neural network architectures and components[J]. *Information Sciences*, 2000, 128(3): 231-255.
- [30] Aharonov D, Ambainis A, Kempe J, et al. Quantum walks on graphs[C]//*Proceedings of the thirty-third annual ACM symposium on Theory of computing*. 2001: 50-59.
- [31] Zhou R, Qin L, Jiang N. Quantum perceptron network[C]//*International Conference on Artificial Neural Networks*. Springer, 2006: 651-657.
- [32] Harrow A W, Hassidim A, Lloyd S. Quantum algorithm for linear systems of equations[J]. *Physical review letters*, 2009, 103(15): 150502.
- [33] Clader B D, Jacobs B C, Sprouse C R. Preconditioned quantum linear system algorithm[J]. *Physical review letters*, 2013, 110(25): 250504.
- [34] Rebstroff P, Mohseni M, Lloyd S. Quantum Support Vector Machine for Big Data Classification[J]. *Physical Review Letters*, 2014, 113(13): 130503.
- [35] Dallaire-Demers P L, Killoran N. Quantum generative adversarial networks[J]. *Physical Review A*, 2018, 98(1): 012324.
- [36] Lloyd S, Weedbrook C. Quantum generative adversarial learning [J]. *Physical review letters*, 2018, 121(4): 040502.
- [37] Bravo-Prieto C, LaRose R, Cerezo M, et al. Variational quantum linear solver[J]. *Quantum*, 2023, 7: 1188.
- [38] Beer K, Bondarenko D, Farrelly T, et al. Training deep quantum neural networks[J]. *Nature Communications*, 2020, 11(1): 808.
- [39] Chen S Y C, Wei T C, Zhang C, et al. Quantum convolutional neural networks for high energy physics data analysis[J]. *Physical Review Research*, 2022, 4(1): 013231.
- [40] Wu J, Fu H, Zhu M, et al. Quantum circuit autoencoder[J]. *Physical Review A*, 2024, 109(3): 032623.
- [41] Li Y, Wang Z, Xing R, et al. Quantum Gated Recurrent Neural Networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2025, 47(4): 2493-2504.
- [42] Li Y, Li Y, Qi Z, et al. QD-MSA : A quantum distributed tensor network framework for multimodal sentiment analysis[J]. *Information Fusion*, 2025, 124: 103404.
- [43] Apolloni B, Carvalho C, De Falco D. Quantum stochastic optimization[J]. *Stochastic Processes and their Applications*, 1989, 33(2): 233-244.
- [44] Narayanan A, Moore M. Quantum-inspired genetic algorithms [C]//*Proceedings of IEEE International Conference on Evolutionary Computation*. 1996: 61-66.
- [45] Han K H, Kim J H. Genetic quantum algorithm and its application to combinatorial optimization problem[C]//*Proceedings of the 2000 congress on evolutionary computation*. CEC00 (Cat. No. 00TH8512): Vol. 2. IEEE, 2000: 1354-1360.
- [46] Han K H, Park K H, Lee C H, et al. Parallel quantum-inspired genetic algorithm for combinatorial optimization problem[C]//*Proceedings of the 2001 congress on evolutionary computation (IEEE Cat. No. 01TH8546)*: Vol. 2. IEEE, 2001: 1422-1429.
- [47] Horn D, Gottlieb A. Algorithm for data clustering in pattern recognition problems based on quantum mechanics[J]. *Physical review letters*, 2001, 88(1): 018702.
- [48] Sun J, Feng B, Xu W. Particle swarm optimization with particles having quantum behavior[C]//*Proceedings of the 2004 congress on evolutionary computation (IEEE Cat. No. 04TH8753)*: Vol. 1. IEEE, 2004: 325-331.
- [49] Jiao L, Li Y, Gong M, et al. Quantum-inspired immune clonal algorithm for global optimization[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2008, 38(5): 1234-1253.