

量子驱动的虚拟现实视口预测 QLook: Quantum-Driven Viewport Prediction for Virtual Reality

Niusha Sabri Kadijani, Yoga Suhas Kuruba Manjunath, Xiaodan Bi, Lian Zhao,

Department of Electrical, Computer & Biomedical Engineering,

Toronto Metropolitan University, Toronto, Canada.

Email: {niusha.sabrikadijani@torontomu.ca, yoga.kuruba@torontomu.ca,
xiaodan.bi@torontomu.ca l5zhao@torontomu.ca}

摘要—我们提出了 QLook, 一个量子驱动预测框架, 以提高沉浸式虚拟现实 (VR) 环境中的视口预测准确性。该框架利用量子神经网络 (QNNs) 对用户运动数据进行建模, 这些数据具有多个相互依赖的维度, 并在六自由度 (6DoF) VR 设置中收集。QNN 利用叠加和纠缠来编码和处理高维用户位置数据之间的复杂相关性。所提出的解决方案采用级联混合架构, 将经典神经网络与变分量子电路 (VQC) 增强的量子长短期记忆 (QLSTM) 网络结合在一起。我们使用身份块初始化来减轻与 VQCs 相关的训练挑战, 特别是那些遇到贫瘠高原的问题。QLook 的经验评估显示, 均方误差 (MSE) 相比最先进的方法降低了 37.4%, 展示了优越的视口预测性能。

Index Terms—虚拟现实, 视口预测, 六自由度, 量子神经网络, 量子长短期记忆。

I. 介绍

沉浸技术的需求因在各个领域的应用而持续增长 [1]。通过头戴式显示器 (HMD) 和手持控制器实现高质量的虚拟现实 (VR) 体验, 需要克服包括实现自适应数据速率、超低延迟和动态系统配置在内的重大技术挑战。对用户而言, 无缝的沉浸体验在 VR 中至关重要, 以避免晕动症的发生, 当视频帧渲染的延迟超过 20 毫秒时, 就会发生这种现象, 这对应于用户的物理动作 [2]。通过提前缓冲所需的视频帧来实现超低延迟是其中一个关键因素。视口, 即用户在 HMD 屏幕上可见的部分视频帧及其预测有助于缓冲所需的视频帧。为了防止晕动症, 在六自由度 (6DoF) 环境中准确预测将要渲染的未来帧的视口至关重要。在这种设置下, 用户在三维空间中的位置和方向会产生多个相互依赖的数据流。

一种基于对象检测和轨迹的方法被提出用于预测 360° 视口, 如 [3] 所示。被动攻击回归模型依赖于这样一个假设: 具有相似过去轨迹的用户共享相同的视口。然而, 这种假设限制了其泛化能力和对未见用户行为的适应性。黄等人。介绍了一个基于上下文多臂老虎机模型来预测视口 [4]。该模型依赖于经验观察到的奖励信号。这些信号是特定于情境的, 无法提前为新用户或不熟悉的场景进行估计, 从而限制了模型的应用范围。李等人。考虑使用长短期记忆 (LSTM) [5] 进行基于瓦片的视口预测。然而, 顺序模型通常难以捕捉短序列中的复杂时间依赖性, 需要访问更多数据才能具有实际适用性。在 [6] 中提出了一种基于深度强化学习的解决方案, 通过利用帧分组方法来预测视口。然而, 其推理时间可能无法满足 VR 应用严格的超低延迟要求。在另一项研究中, 提出了一种使用头部和身体姿态 [7] 的视口预测解决方案。然而, 位置和头部方向数据被单独处理, 这忽视了它们之间的相互依赖关系, 并将问题过度简化为经典神经网络可以处理的形式, 导致更高的预测误差和降低的准确性。Ouellette 等人。提出了唯一现有的基于 GRU 的模型, 用于使用头部和身体轨迹 [8] 的 6 自由度视口预测。我们将其视为利用时间建模进行细粒度 6 自由度预测的最先进技术 (SoTA), 尽管其在泛化和准确性方面存在局限性, 但它是最新的可用方法。

大多数现有的研究集中在 360° 视频数据上, 其中用户仅通过头部旋转来探索环境。先前的研究忽略了 6

自由度 VR 场景，其中用户可以在位置和方向上自由移动。传统方法将位置和头部朝向数据独立处理。分别建模无法捕捉到在 6 自由度 VR 中身体和头部运动之间的相互影响。诸如 LSTM 之类的序列模型需要较长的序列和较大的参数集来学习复杂的时序依赖关系。在 6 自由度 VR 中，由于序列较短且数据噪声较大，预测误差会随时间传播，从而降低性能。

量子神经网络 (QNNs) 借助叠加和纠缠，为建模六自由度虚拟现实视口预测中的高维和相互依赖的用户运动数据提供了有前景的能力。叠加使量子并行性能能够高效地探索复杂的特征空间。纠缠在量子态之间引入了强烈的关联，使得模型可以捕捉到用户运动模式中固有的非局部依赖关系，在这种模式下，身体位置与头部方向动态影响彼此。量子长短时记忆 (QLSTM) 是一种著名的 QNN，它在识别复杂和高维时间数据中的模式方面表现出色 [9]。PennyLane 引入的 QLSTM 架构是使用变分量子电路 (VQCs) 实现的 [10]。VQCs 为嘈杂中尺度量子 (NISQ) 设备中的经典优化器提供了强大的错误校正 [11]。然而，VQC 在训练期间特别难以处理贫瘠高原问题 [12]。因此，我们在复杂的高维六自由度 VR 设置中研究用于视口预测的 QLSTM。

为解决研究缺口，我们提出了一种结合身体定位数据与头部朝向的 QLook 框架，该框架采用级联量子驱动方法进行 6DoF VR 视口预测。所提出的级联模型的第一阶段使用 LSTM 形成，用于预测位置数据。预测的位置数据随后与头部朝向数据相结合，以构成第二阶段输入，该阶段通过 QLSTM 形成。我们使用真实世界的数据集 [13] 对我们的方法进行了全面的实证评估，包括对比两种基线模型，其中之一是级联经典 LSTM 模型。我们的结果显示，在视口预测准确性方面相比 SoTA [8] 提升了 37.4%。据我们所知，这是我们首次研究在 6DoF VR 设置中使用 QLSTM 进行视口预测的工作。

II. 系统模型

解决方案的系统模型如图 1 所示。多接入边缘计算 (MEC) 服务于多个 VR 用户。头戴显示器显示虚拟环境的视野部分，同时持续追踪用户的视线。控制器提供额外的位置数据。HMD 将捕获到的传感器数据传输至 MEC，在这里 QLook 框架预测视口。如果帧已缓存在 MEC 中，则一旦预测出视口，MEC 就会渲染对应的帧并将这些帧发送给 HMD。精确的视口预测使相应的帧




图 1: 系统模型

能够预先缓冲并渲染到 HMD 上，以避免晕动症，并提供无缝体验。

A. 问题公式化

在一个 6 自由度的 VR 环境中，预测用户未来的视野区域涉及估计随时间变化的空间位置和旋转方向。在每个时间步骤 t 中，定义一个数据点为一个给定的 32 维向量，

$$\mathbf{m}_t = (\tau_t, \mathbf{p}_t, \mathbf{e}_t, \mathbf{c}_t, \mathbf{a}_t), \quad (1)$$

其中 τ_t 是时间戳； $\mathbf{p}_t \in \mathbb{R}^3$ 表示坐标 (x, y, z) 中的 3D 位置； $\mathbf{e}_t \in \mathbb{R}^3$ 表示欧拉角（俯仰、翻滚、偏航）中的头部方向； $\mathbf{c}_t \in \mathbb{R}^3$ 表示控制器的位置； $\mathbf{a}_t \in \mathbb{R}^{23}$ 包括其他特征，如触控按钮状态和派生特征，以丰富数据集表示。

对于第一个预测阶段，我们定义一个输入向量：

$$\mathbf{q}_t = (\tau_t, \mathbf{p}_t), \quad (2)$$

以及由过去 n 个时间步长从 t_k 到 t_{k-n+1} 形成的相应输入矩阵，给出为：

$$\mathbf{Q}_{t_k} = [\mathbf{q}_{t_k}, \mathbf{q}_{t_{k-1}}, \dots, \mathbf{q}_{t_{k-n+1}}], \quad (3)$$

其中 k 表示输入序列窗口的起始索引。第一个预测函数 ψ 预估未来用户在三个轴上的位置 (x, y, z) ：

$$\hat{\mathbf{p}}_k = \psi(\mathbf{Q}_{t_k}). \quad (4)$$

预测 $\hat{\mathbf{p}}_k$ 后，将预测位置与其他特征拼接，并作为输入向量：

$$\mathbf{m}_{t_{k+n}} = (\hat{\mathbf{p}}_{t_{k+n}}, \mathbf{e}_{t_{k+n-1}}, \mathbf{c}_{t_{k+n-1}}, \mathbf{a}_{t_{k+n-1}}), \quad (5)$$

和我们定义第二预测阶段的完整输入矩阵为：

$$\mathbf{M}_{t_k} = [\mathbf{m}_{t_k}, \mathbf{m}_{t_{k-1}}, \dots, \mathbf{m}_{t_{k-n+1}}]. \quad (6)$$

第二个预测函数 ϕ 使用该序列来预测由 (x, y, z) 轴上的欧拉角表示的未来头部方向：

$$\hat{\mathbf{y}}_k = \phi(\mathbf{M}_{t_k}). \quad (7)$$

所提出的框架求解方程 (4) 和 (7) 以找到预测函数。




图 2: VQC 的架构, 其中 (θ_i) 和 (ϕ_i) 是从经典输入数据编码而来的, 而 $(\alpha_i, \beta_i, \gamma_i)$ 对于 $i = 1, 2, 3, 4$ 是可训练参数, 遵循了在 [17] 中引入的设计。

III. 量子 LSTM 的预备知识

A. 变分量子电路

叠加和纠缠是量子计算的可区分特性。量子计算使用量子比特。一个量子比特可以具有一个状态或一组基态的组合。作为量子状态的基态线性组合称为叠加 [14]。无论量子比特如何纠缠, 量子态之间的相关性都保持完整 [14]。NISQ 是当前一代的量子计算机。缺乏门错误纠正和量子比特数量的限制是 NISQ [12] 的缺点, 这些缺点限制了 NISQ 在大规模量子计算中的应用。VQC 提供了一种利用 NISQ 设备进行大规模量子计算的实用方法, 包括量子本征值求解器 [15] 和量子神经网络。作为量子电路的 VQC 是硬件高效的。参数化量子电路的浅层深度缓解了 NISQ 的缺乏错误纠正问题 [11]。VQC 将参数化部分的训练过程委托给经典梯度优化器, 从而减轻了 NISQ 设备的限制。VQC 使用较短的门序列执行更高效的操作, 这使得它们特别适合于 NISQ 设备 [16]。一个典型的 VQC 如图 2 所示。VQC 由三个主要组件组成。第一个组件是编码层, 它使用角度编码将经典输入数据映射到量子态, 这通过 Hadamard、Pauli-X 和 Pauli-Z 门实现。第二个组件是参数化量子层, 其中包含在训练过程中使用经典的梯度方法优化的可调参数的可训练量子门。最后一个组件是测量层, 它塌缩量子态以产生经典输出。这些输出, 即期望值, 然后被集成到混合量子-经典模型中的经典模型所使用。

B. QLSTM 单元

通过将 VQC 集成到 LSTM [17] 的门控机制的内部内存动态中, QLSTM 能够在希尔伯特空间中编码信息, 这提供了表达能力和潜在的性能优势。在一个经典的 LSTM 中, 全连接层通常处理门函数内的每次线性

变换。相比之下, 在 QLSTM 中, 它们被 VQC 模块所取代, 每个模块作用于连接的输入向量 $v_t = [h_{t-1}, x_t]$ 其中 h_{t-1} 是上一时间步的隐藏状态, x_t 是当前输入。QLSTM 单元在每个时间步骤 t 执行以下操作:

$$f_t = \sigma(\text{VQC}_1(v_t)), \quad \text{forget gate} \quad (8)$$

$$i_t = \sigma(\text{VQC}_2(v_t)), \quad \text{input gate} \quad (9)$$

$$\tilde{C}_t = \tanh(\text{VQC}_3(v_t)), \quad \text{cell candidate} \quad (10)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{C}_t, \quad \text{cell state update} \quad (11)$$

$$o_t = \sigma(\text{VQC}_4(v_t)), \quad \text{output gate} \quad (12)$$

$$h_t = \text{VQC}_5(o_t \odot \tanh(c_t)), \quad \text{hidden state} \quad (13)$$

$$y_t = \text{VQC}_6(o_t \odot \tanh(c_t)), \quad \text{output} \quad (14)$$

其中, σ 和 $\tanh$ 分别表示 sigmoid 激活函数和双曲正切激活函数。每个 VQC 块通过参数化量子电路处理其输入, 然后进行量子测量, 从而产生一组期望值向量。测量的输出作为 LSTM 中经典权重矩阵和偏置项的量子对应物, 在经过经典激活之前提供增强的非线性变换。

IV. 方法论

A. 模型架构

我们提出了 QLook, 一个基于量子驱动的深度神经网络构建的级联模型来解决方程 (4) 和 (7)。如图 3 所示, QLook 架构建立在两个模块之上。第一个模块是一个堆叠的标准 LSTM 网络, 因其更快的推理时间而被选中。第一个模块被训练以预测沿 (x, y, z) 轴的位置数据, 以求解方程 (4)。QLSTM 模块作为第二个模块, 求解方程 (7)。从第一个模块中预测的身体位置数据, 连同控制器数据以及另外两个提取的特征: 头部速度和头部加速度, 一起输入到 QLSTM 模块中。级联模型的输出提供了由三个轴上的欧拉角表示的方向数据。

B. 数据增强和初始化

在预处理阶段, 高斯噪声被整合到了训练数据中。它从一个零均值正态分布 $\mathcal{N}(0, \sigma^2)$ 中采样, 其中标准差 σ 基于初步实验经验设置为 2。高斯噪声是文献中广泛采用的方法之一, 用于建模随机传感器误差, 并在机器学习应用中模拟现实世界的不确定性。这种增强增加了数据集的复杂性, 并促使 QLSTM 模块学习更有意义的模式, 而不是记忆特定细节。因此, 它增强了模型的鲁棒性和泛化能力, 使模型能够更好地处理未见 VR 数据中的变异性。




图 3: QLook 架构的演示

QLSTM 架构建立在 VQC 上，容易受到初始化不良的影响。VQCs 特别容易遭受贫瘠高原问题的影响，在这个问题中，梯度随着电路深度的增加而消失 [15]。为了减轻 QLSTM 中不足的初始化影响，我们采用了由 [15] 原先提出的恒等块初始化技术。标准 VQC 的参数化部分通常如图所示 2 随机初始化而不强制保持恒等性，这经常导致梯度消失。相比之下，每个变分块都是由一对镜像层构成的。每一层对每一个量子比特应用形式为 $R(\alpha_i, \beta_i, \gamma_i)$ 的参数化单量子比特旋转。第 1 层使用参数 $(\alpha_i, \beta_i, \gamma_i)$ ，而第 2 层初始化为 $(-\alpha_i, -\beta_i, -\gamma_i)$ ，以确保组合操作满足 $R(\alpha_i, \beta_i, \gamma_i) \cdot R(-\alpha_i, -\beta_i, -\gamma_i) = I$ 。通过将这一部分初始化为恒等操作，量子层变得易于训练，这增强了模型的整体收敛性。

V. 结果与讨论

A. 模型设计与实现细节

Meta Quest 2 用作每秒 90 帧的头戴显示器，这使我们能够在 11.11 毫秒的时间窗口内预测视口。鉴于这一限制，模型应在时间要求范围内准确预测视口。因此，我们采用 LSTM 模块以保证实时性能。由于对图形处理单元 (GPUs) 的计算需求，QLSTM 的推理时间仍然慢于 LSTM。因此，我们将第一个模块设计为 LSTM，以确保快速推理并满足设备的实时限制。

我们使用 Python 3.9.20，结合 PyTorch 2.5.1 和 PennyLane 0.38 来实现所提出的框架用于量子电路模拟。所有实验在一个配备双 NVIDIA RTX A5000 GPU（每个具有 24GB 显存）和 128GB 内存的服务器上进行。详细超参数和模型配置汇总于表 I 中。

表 I: 超参数和 LSTM 及 QLSTM 模块的架构细节

参数	模块 1 (LSTM)	模块 2 (QLSTM)
Training epochs	50	50
Learning rate	0.001	0.001
Sequence length	10	10
Hidden units	32	100
Number of layers	2	2
Batch size	32	64
Dropout rate	0.2	0.2
Optimizer	Adam	Adam
Quantum components	—	4 qubits, 2 VQC layers

B. 数据集详情

我们使用了 Questset 数据集 [13]，它提供了在 VR 会话期间捕捉用户头部朝向和身体位置的 6DoF 运动数据。这个数据集非常适合我们的工作，因为它为沉浸式 VR 环境中的用户提供真实的运动数据，使我们评估所提出的 QLook 框架在不同交互速度和动作模式下的鲁棒性和泛化能力。虽然多用户的 VR 场景更能反映现实情况，但目前这类数据集不可用。

总计，我们用于此项研究的数据集部分包含大约 477,000 个样本。我们选择了来自第 1 组和第 2 组的用户 2 到 8，更多信息请参见数据集 [13]。我们使用可用样本的 42% 来进行实验。在此子集中，我们将数据按 60%-20%-20% 的比例划分为训练、验证和测试集。我们采用滑动窗口方法将数据分割成顺序窗口，以保持每个序列中的时间依赖性。

C. 性能比较和定量评估

我们实现了一个由两个 LSTM 模块组成的级联经典 LSTM 作为基准，其超参数与 QLook 框架相同。我们使用在训练后测试集上计算的均方误差 (MSE) 来评估预测性能。QLook 实现了 0.087 的 MSE。级联经典模型在数据集的测试集上的 MSE 为 0.109，这表明量子驱动框架具有更好的预测性能。在 GPU 上模拟量子电路是计算密集型任务；训练 QLook 框架需要 170,991.85 秒，而级联经典 LSTM 仅需 3,458.16 秒完成。如表 II 所示，QLook 的可训练参数数量显著较少，大约比级联经典 LSTM 少 99%。这种减少表明，在专用量子硬件上执行时，推理时间可能会大幅缩短，正如量子霸权所暗示的那样。模型泛化能力和鲁棒性也是评估的重要方面，在图 4 中得到了展示。我们将泛化定义为模型准确预测未见用户数据中的头部和身体位置模式的能力，这些数据并未包含在训练阶段中。为了提供一个具有代表

表 II: QLook 和基线模型的比较

Model	De- scrip- tion	MSE	Improvement	# Parameters
QLook	Cas- cade classical- quantum model	0.087	—	1,335
Baselines	Cas- cade clas- sical model	0.109	20.11%	134,703
	SoTA [8]	0.140	37.4%	40,503

表 III: 模型的 RMSE 比较

模型	欧拉 X	欧拉 Y	欧拉 Z
QLook	0.253	0.028	0.438
Cascade Classical	0.289	0.168	0.456
SoTA [8]	0.333	0.100	0.510

性的评估，训练好的模型被用于测试五位用户：0、1、9-11 号，这几位用户是从第 1 阶的组别 1 和 2 中根据问卷 [13] 中概述的用户特征选出的。我们从这些用户的数据中进行选择，以捕捉与 VR 场景相关的多样化行为模式。表 III 显示了 QLook 优越的预测性能，突出了其在未见过用户数据上的泛化能力。图 5 显示 QLook 更加紧密地遵循欧拉 Z 模式，并且比基线模型更加准确地保持时间动态。

D. 身份块效果

QLSTM 模块在 QLook 框架中面临训练期间的平庸高原挑战，这减缓了量子参数优化和收敛速度。这种行为可以在图 6 中观察到，其中训练损失保持在较高的数值。身份块被引入到 QLSTM 架构中，并作为解决此问题的有效方案，促进了更平稳的收敛并提升了模型的学习能力。图 6 展示了一个 epoch 内每小批量迭代级别的训练损失，比较了具有和不具有身份块的 QLSTM 模块性能。结果显示，引入身份块导致更快的收敛和更加稳定的训练过程。

VI. 结论

本文提出了一种用于预测 6DoF 环境中的视口的 QLook 架构。我们的结果表明，QLook 框架在视口预测中实现了更高的精度。展示了量子经典混合模型在推




图 4: 选定用户之间的 RMSE 比较，显示 QLook 的误差率低于基线。




图 5: 欧拉 Z 预测在 200 个样本上的比较。QLook（橙色虚线）与基线相比，更紧密地跟踪了真实值（绿色实线）。

进沉浸式 VR 体验方面的潜力。身份块有助于我们的解决方案更快地收敛。我们的方法对于不同用户的数据显示了准确性和可扩展性。据我们所知，QLook 是第一个研究量子在 VR 视口预测中的适用性的作品。

在未来，我们将研究一种基于 QNN 的缓存策略，以进一步减少 VR 流媒体设置中的延迟。我们还计划将我们的工作扩展到多个用户同时交互的情景中，超越目前对独立用户行为的假设。

参考文献

- [1] Q. Zhang, J. Wei, S. Wang, S. Ma, and W. Gao, "RealVR: Efficient, economical, and quality-of-experience-driven VR video system based on MPEG OMAF," *IEEE Transactions on Multimedia*, vol. 25, pp. 5386–5399, 2022.
- [2] R. Yao, T. Heath, A. Davies, T. Forsyth, N. Mitchell, and P. Hoberman, "Oculus VR best practices guide," *Oculus VR*, vol. 4, pp. 27–35, 2014.
- [3] Y. Jin, J. Liu, F. Wang, and S. Cui, "Eublibio: Edge-assisted multiuser 360 video streaming," *IEEE Internet of Things Journal*, vol. 10, no. 17, pp. 15 408–15 419, 2023.
- [4] Z. Huang, P. Yang, W. Wu, and N. Zhang, "Predictive and Robust Field-of-View Selection for Virtual Reality Video Streaming," in *2023 IEEE 34th Annual International Symposium on Personal,*




图 6: 身份块对 QLSTM 模块收敛行为的影响。添加身份块有助于模型更快地收敛并达到比没有身份初始化的标准 QLSTM 更低的损失。

- Indoor and Mobile Radio Communications (PIMRC)*. IEEE, 2023, pp. 1–6.
- [5] M. Li, J. Gao, C. Zhou, X. Shen, and W. Zhuang, “User dynamics-aware edge caching and computing for mobile virtual reality,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 17, no. 5, pp. 1131–1146, 2023.
- [6] S. Bi, H. Chen, X. Li, S. Wang, Y. Wu, and L. Qian, “A two-stage deep reinforcement learning framework for MEC-enabled adaptive 360-degree video streaming,” *IEEE Transactions on Mobile Computing*, 2024.
- [7] X. Hou and S. Dey, “Motion prediction and pre-rendering at the edge to enable ultra-low latency mobile 6DoF experiences,” *IEEE Open Journal of the Communications Society*, vol. 1, pp. 1674–1690, 2020.
- [8] J. Ouellette and A. Bentaleb, “LL-Sparse: Low-latency 6-DoF field of view prediction,” in *Proceedings of the 16th ACM Multimedia Systems Conference*, 2025, pp. 57–67.
- [9] M. Emu, T. Rahman, S. Choudhury, and K. Salomaa, “Quantum long short-term memory-assisted optimization for efficient vehicle platooning in connected and autonomous systems,” *IEEE Open Journal of the Computer Society*, 2024.
- [10] V. Bergholm, J. Izaac, M. Schuld, C. Gogolin, M. S. Alam, S. Ahmed, J. M. Arrazola, C. Blank, A. Delgado, S. Jahangiri *et al.*, “Pennylane: Automatic differentiation of hybrid quantum-classical computations,” *arXiv preprint arXiv:1811.04968*, 2020.
- [11] M. Cerezo, A. Arrasmith, R. Babbush, S. C. Benjamin, S. Endo, K. Fujii, J. R. McClean, K. Mitarai, X. Yuan, L. Cincio *et al.*, “Variational quantum algorithms,” *Nature Reviews Physics*, vol. 3, no. 9, pp. 625–644, 2021.
- [12] M. Cerezo, A. Sone, T. Volkoff, L. Cincio, and P. J. Coles, “Cost function dependent barren plateaus in shallow parametrized quantum circuits,” *Nature communications*, vol. 12, no. 1, p. 1791, 2021.
- [13] S. Baldoni, F. Battisti, F. Chiariotti, F. Mistrorigo, A. B. Shofi, P. Testolina, A. Traspadini, A. Zanella, and M. Zorzi, “Questset: A VR dataset for network and quality of experience studies,” in *Proceedings of the 15th ACM Multimedia Systems Conference*, 2024, pp. 408–414.
- [14] D. Bouwmeester and A. Zeilinger, “The physics of quantum information: basic concepts,” in *The physics of quantum information: quantum cryptography, quantum teleportation, quantum computation*. Springer, 2000, pp. 1–14.

- [15] E. Grant, L. Wossnig, M. Ostaszewski, and M. Benedetti, “An initialization strategy for addressing barren plateaus in parametrized quantum circuits,” *Quantum*, vol. 3, p. 214, 2019.
- [16] M. Schuld and N. Killoran, “Quantum machine learning in feature hilbert spaces,” *Physical review letters*, vol. 122, no. 4, p. 040504, 2019.
- [17] S. Y.-C. Chen, S. Yoo, and Y.-L. L. Fang, “Quantum long short-term memory,” in *ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2022, pp. 8622–8626.
- [18] J. Biamonte, P. Wittek, N. Pancotti, P. Rebentrost, N. Wiebe, and S. Lloyd, “Quantum machine learning,” *Nature*, vol. 549, no. 7671, pp. 195–202, 2017.