

基于量子深度学习的遥感图像处理研究进展

徐若恒

桂林理工大学物理与电子信息工程学院, 广西 桂林

收稿日期: 2026年6月5日; 录用日期: 2026年7月3日; 发布日期: 2026年7月8日

摘要

本文系统综述了混合量子-经典计算架构在遥感图像处理中的应用现状, 探索量子计算突破传统深度学习参数与算力瓶颈的理论潜力。梳理了含噪声中等规模量子(NISQ)时代下, 量子深度学习(QDL)在图像分类与特征提取、高维光谱数据降维、小样本生成等任务中的研究进展, 并剖析了多种量子数据编码策略的机制。对比现有文献发现, 该交叉领域仍受制于数据编码效率、硬件退相干与梯度消失(贫瘠高原)、异构协同融合缺失等底层局限。针对上述制约, 前瞻性探讨了量子迁移学习、张量网络、量子架构搜索(QNAS)等新兴技术在提升模型抗噪性与特征表征能力方面的演进趋势。结论指出, 软硬件协同优化与误差缓解算法的深化, 有望使量子深度学习成为多模态地球观测数据智能化解译中一种具备参数效能潜力的补充计算范式。

关键词

量子深度学习, 遥感图像, 量子计算

Research Progress of Remote Sensing Image Processing Based on Quantum Deep Learning

Ruoheng Xu

School of Physics and Electronic Information Engineering, Guilin University of Technology, Guilin Guangxi

Received: June 5, 2026; accepted: July 3, 2026; published: July 8, 2026

Abstract

This paper presents a systematic review of the current state of hybrid quantum classical computing architectures for remote sensing image processing, aiming to explore the theoretical potential of quantum computing to overcome the constraints of parameter explosion and computational cost inherent

in traditional deep learning. In the Noisy Intermediate Scale Quantum (NISQ) era, the review summarizes research progress in quantum deep learning (QDL) for core tasks including image classification and feature extraction, dimensionality reduction of high dimensional spectral data, and few shot data generation. It also analyzes the underlying mechanisms of various quantum data encoding strategies. A comparative analysis of existing literature reveals that this interdisciplinary field is still hindered by fundamental limitations such as data encoding inefficiency for high resolution inputs, hardware decoherence and vanishing gradients (the barren plateau phenomenon), and the lack of effective heterogeneous synergy mechanisms. In response to these constraints, this paper prospectively discusses emerging technologies (quantum transfer learning, tensor networks, and quantum architecture search (QNAS)) and their evolutionary trends in enhancing model robustness and feature representation capability. The conclusion indicates that deeper integration of software hardware co optimization and error mitigation algorithms may enable quantum deep learning to serve as a complementary computing paradigm with parameter efficiency for the intelligent interpretation of multi modal Earth observation data in the future.

Keywords

Quantum Deep Learning, Remote Sensing Imagery, Quantum Computing

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

遥感技术是获取地表空间分布、动态演化特征以及多谱段辐射信息的重要手段。近年来，以卷积神经网络(CNNs)和视觉大模型(Vision Transformers, ViTs)为代表的深度学习算法在遥感图像场景分类、目标检测与地物分割等任务中得到了广泛应用[1]。然而，随着现代对地观测系统的发展，遥感数据呈现出多源、多尺度以及高维度的特性。传统计算范式在进行海量数据挖掘与深层特征解译时，逐渐显露出冯·诺依曼架构下的算力与存储带宽限制[2]。传统深度学习模型在提取复杂遥感地物的高阶空间相关性或多光谱通道间的非线性映射时，通常依赖于网络深度的指数级增加与参数数量的持续堆叠。这种范式不仅对底层物理硬件的计算能效提出了挑战，还在处理高频细节时容易引发过拟合现象[3]。

在此背景下，量子机器学习(Quantum Machine Learning, QML)作为一种基于量子力学原理的新型计算范式受到学术界关注[4]。研究表明，量子计算系统依托量子态的叠加原理与纠缠机制，在突破经典局部算子限制、进行高维非线性特征映射方面具备底层物理优势[5]。具体而言，一个包含 N 个量子比特的系统能够张成一个 2^N 维的希尔伯特空间，这为指数级的高维特征映射提供了潜在的物理载体。然而，当前量子计算硬件仍处于含噪声中等规模量子(Noisy Intermediate-Scale Quantum, NISQ)时代，受限于物理量子比特数量(通常在百比特至千比特量级)与退相干时间，要求长相干时间的纯量子算法(如 HHL 算法或 Shor 算法)难以直接部署于高维图像处理任务[6]。因此，将参数化量子电路(Parameterized Quantum Circuit, PQC)与经典神经网络相结合的变分混合计算范式，即混合量子深度学习(Quantum Deep Learning, QDL)，成为现阶段探索高分辨率遥感图像处理的可行方案[7]。该类架构利用经典计算机处理非线性激活与大规模参数寻优，同时利用量子处理器(QPU)处理高维特征张量的线性变换，在理论上兼顾了量子表达优势与经典可训练性。

本文系统梳理了混合量子深度学习在遥感图像处理中的应用现状，深入对比分析不同架构与量子编码机制的技术特征，并探讨该领域面临的物理局限与演进趋势。

2. 混合量子 - 经典计算架构与编码机制

2.1. 混合架构概述

混合量子 - 经典计算架构的核心思路在于实现异构计算资源的协同。该工作流通常可拆解为三个主要阶段：数据降维与预处理、量子特征映射与测量、以及经典反向传播与参数优化。

首先，经典计算机负责高维遥感数据的加载。由于 NISQ 设备的比特数限制，原始高分辨率影像(如 256×256 像素)通常需经过主成分分析(PCA)或经典自编码器(Autoencoder)进行前端降维，提取出低维潜向量(Latent Vector)。随后，降维后的特征输入至 QPU。通过特定的量子数据编码策略，经典实数向量被映射为希尔伯特空间中的量子态。

在特征演化阶段，参数化量子电路(PQC)开始执行操作。PQC 由一系列固定的逻辑门(如 Hadamard 门、CNOT 门)与可调参数的旋转门(如 $RX(\theta)$ 、 $RY(\theta)$ 、 $RZ(\theta)$)组成。其数学本质是执行一个高度参数化的酉变换 $U(\theta)$ ，在局部特征之间建立非局部关联。经过特定深度的量子线路计算后，系统通过对特定的量子比特执行泡利可观测量的测量(Measurement)，将其坍缩为经典期望值标量输出。

最后，经典计算机接收该期望值，计算其与真实标签之间的损失函数，并采用经典优化器(如 Adam 或梯度下降算法)反向更新 PQC 的参数 θ [8]，在物理实现上，梯度计算无法直接应用经典的链式法则，而是通常依赖于“参数位移规则”(Parameter-Shift Rule)以解析的方式在量子硬件上评估梯度[9]。图 1 展示了该混合计算范式在图像处理中的异构协同流程。

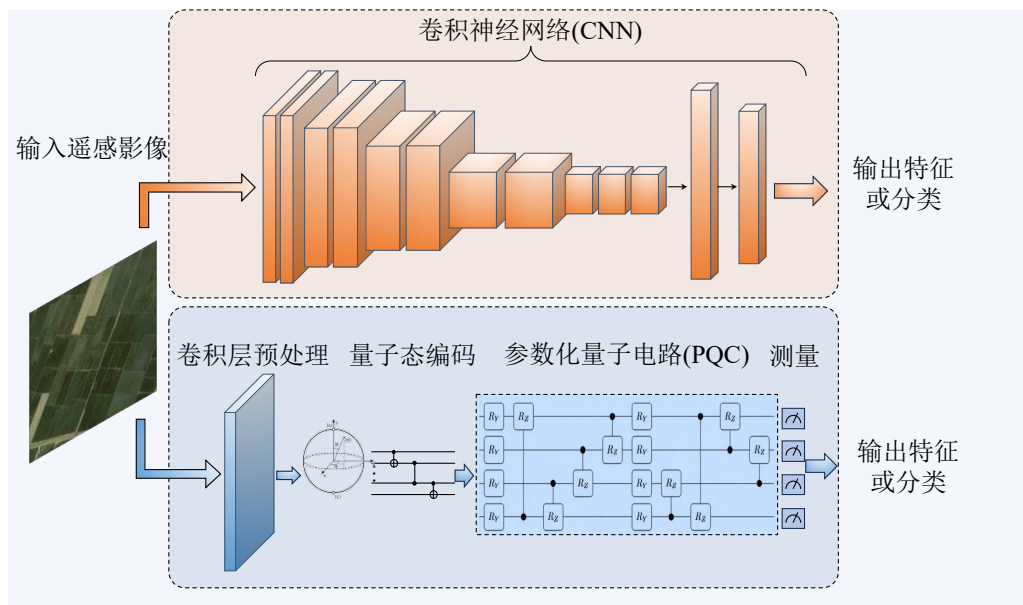


Figure 1. A comparison of workflows between classical deep learning and quantum deep learning in image processing
图 1. 经典深度学习与量子深度学习在图像处理中的工作流对比

2.2. 量子数据编码策略比较

在处理遥感图像时，将经典连续像素值转换为量子态(Quantum Data Encoding)是影响模型性能的首要环节。目前主要存在三种编码策略，在资源消耗与特征保留方面存在差异：角度编码(Angle Encoding)将经典数据编码为量子比特的旋转角度，该方法线路深度浅，适合 NISQ 设备，但需消耗数量与特征维度呈线性关系的量子比特，在处理高分辨率遥感图像时面临硬件维度限制[10]；振幅编码(Amplitude

Encoding)将经典向量的元素编码为量子态的概率振幅,该策略能以对数级量子比特表示指数级数据(例如 N 个比特可编码 2^N 维特征),理论上具备较高的数据压缩率,但其量子态制备电路深度较长,易受硬件噪声干扰[11];基态编码(Basis Encoding)将经典二进制数据直接映射为计算基态,该方法在保留遥感图像精确数值方面表现较好,但资源消耗过大,当前多用于概念验证阶段的小尺寸图像处理[12]。

3. 量子深度学习在遥感核心任务中的应用进展

随着变分量子算法的发展,研究者逐步将混合量子神经网络架构应用于遥感领域的核心任务中,涵盖了从监督类的分类识别到无监督的降维与生成等多个场景。

3.1. 场景分类与空间特征提取

经典 CNN 在提取空间局部特征时表现优异,而量子卷积神经网络(QCNN)则试图通过量子逻辑门替换经典卷积核,以实现更高维度的特征映射。Sebastianelli 等人[13]利用预训练的 ResNet 提取深层语义特征后,将降维后的特征向量输入 PQC 进行分类决策,在有限的参数空间内验证了其有效性。针对复杂遥感地物的识别,Fan 等人[14]提出了一种混合量子-经典卷积神经网络(HQCNN)。在 EuroSAT 等数据集上的测试表明,在达到相近分类准确率的条件下,HQCNN 所需的可训练参数量仅为经典基线模型的 10%至 20%。

随着网络深度的增加,PQC 的反向传播同样面临梯度衰减问题。为此,Liang 等人[15]设计了量子跳跃连接架构(HQResNet),通过引入恒等映射通道缓解了信息损耗。另一方面,针对遥感图像中背景复杂的问题,近期研究开始尝试将量子注意力机制(Quantum Attention)融入混合模型。Zhao 等人[16]的研究表明,通过受控纠缠线路对不同空间区域或光谱通道的特征权重进行叠加与相位干涉,能够在理论上提供比经典点积操作更复杂的非线性权重分配机制。

3.2. 高维光谱数据降维处理

高光谱遥感图像(HSI)通常包含数十乃至数百个连续的光谱波段,直接输入分类器极易引发“维数灾难”。Otgonbaatar 等人[17]探索了量子退火算法在特征选择中的应用,将其映射为二次无约束二值优化(QUBO)形式。利用 D-Wave 量子退火机的量子隧穿效应,系统能够以更大概率搜索到全局最优的波段特征子集。在极化合成孔径雷达(PolSAR)处理方面,该团队进一步尝试将雷达信号的斯托克斯(Stokes)参数直接嵌入到量子旋转门的相位中[18],探索了物理启发的量子编码在雷达电磁特征表征中的适用性。

3.3. 小样本图像生成与分布学习

在遥感观测任务中,高质量像素级标注数据的获取成本极高。量子生成对抗网络(QGANs)尝试利用参数化量子电路作为生成器。理论研究表明,QGAN 利用多比特系统的相干叠加性质拟合高维概率分布时,相较于经典 GAN 具有更强的表达能力,并在抑制模式崩塌(Mode Collapse)方面表现出潜在优势[19]。现有的软硬件协同实验表明,QGAN 在生成低维遥感纹理特征与数据扩充方面,已提供了一种具有可行性的探索路径[20]。

4. 量子深度学习应对遥感特有挑战的理论机制探讨

虽然上述混合量子算法在通用视觉任务中已有应用,但其底层物理机制在应对遥感对地观测特有挑战时,展现出具备高度针对性的理论契合度。

4.1. 高维高光谱数据的“维数灾难”应对

面对高光谱影像密集的空谱联合特征,传统模型极易产生参数膨胀。量子计算系统能够利用 n 个量

量子比特的张量积态构建 2^N 维的指数级特征空间。这种物理属性使得基于基态或振幅编码的量子核方法 (Quantum Kernel Methods), 能够在不显式增加模型参数的前提下, 计算高光谱像元在极高维希尔伯特空间中的内积相似度, 从而在理论上提供了一种规避经典“维数灾难”的非线性映射路径[21]。

4.2. 多模态遥感数据的异构协同融合

现代地球观测高度依赖多模态数据(如光学影像与 SAR 数据)的融合。经典多流网络融合机制算力消耗巨大, 而量子计算中的纠缠门(如 CNOT、CZ 门)天然具备在不同物理比特间建立非局部相关性的能力。通过将不同模态的特征分量分别编码于独立的量子寄存器, 并运用受控纠缠线路操作, 模型能在极低参数空间内隐式捕捉光学与雷达特征之间的高阶非线性交互关系, 为多源异构数据的特征级对齐提供了新的数学框架。

4.3. 小样本条件下的地物泛化识别

灾害监测等特定遥感任务长期面临可用样本匮乏的困境。理论研究表明, 参数化量子电路在 VC 维 (Vapnik-Chervonenkis Dimension) 等统计学习指标上, 具有比经典神经网络更紧凑的泛化误差界限[22]。这意味着在面对极小规模遥感训练集时, 混合量子模型相较于经典深度网络更不容易陷入经验风险过拟合。利用量子态的相干叠加特性进行小样本分布拟合, 成为应对遥感罕见地物识别的核心潜在优势。

Table 1. Comparison of core architectures of hybrid quantum deep learning in remote sensing and image processing
表 1. 混合量子深度学习在遥感及图像处理领域的核心架构对比

模型名称	基础架构	编码策略	量子资源估算(比特数/线路深度)	抗噪鲁棒性	遥感数据适应性	优势与局限性
HQCNN [14]	CNN 预特征提取	振幅编码	$O(\log(N))$ /较深 $O(\text{poly}(N))$	弱	光学/多光谱图像	展现出极高的参数压缩比; 深度纠缠线路在真实硬件上易因噪声引发计算失效
HQResNet [15]	ResNet18	角度编码	$O(N)$ /较浅 $O(1)$	中等	高空间分辨率影像	恒等映射通道缓解了深度 PQC 的梯度消失; 硬件比特限制导致仅能处理前端大幅降维后的粗粒度特征
QSVM [11]	SVM	量子特征映射	视截断子集而定/ 中等	较强	高光谱数据	在特定低维光谱子集上显现出复杂的非线性分类边界; 无法直接处理包含密集空间相关性的高分辨率全图
QGAN [19]	GAN	混合参数化态制备	$O(\log(N))$ /视潜在空间而定	较弱	简化纹理/生成	理论上相较于经典 GAN 具有更优的泛化界限, 缓解模式崩塌; 受限于相干时间, 当前生成样本的像元分辨率极低。

通过对现有混合架构的对比分析可以发现, 量子模型在实际遥感任务中的表现高度依赖于其编码策略与硬件特性的适配度(见表 1)。振幅编码策略虽然在理论上能以 $O(\log N)$ 的量子比特数量实现指数级的数据压缩, 但其态制备线路深度通常达到 $O(\text{poly}(N))$ 。这种深层线路在当前 NISQ 设备的退相干噪声

下缺乏计算鲁棒性，更适合处理抗噪要求较低的低维特征。相反，角度编码线路深度为 $O(1)$ ，对硬件噪声具有较强的抵御能力，但其 $O(N)$ 的比特消耗限制了其在极化 SAR 或高光谱等高维度张量数据上的直接应用。因此，评估混合量子模型时，不能仅局限于经典指标，而必须在量子资源约束、抗噪鲁棒性以及特定遥感模态的适应性之间进行理论折中。

5. 物理局限与算法挑战

通过上述文献的归纳对比可知，尽管混合量子深度学习在部分遥感场景展现出理论潜力，但要实现空天信息技术领域的工程化落地，当前仍需克服一系列严峻的底层局限性。

首先，量子数据编码面临不可忽视的效率瓶颈。遥感影像具备极高密度的空间纹理与高频细节信息。如前文所述，现有的三种编码策略难以在“低资源消耗”与“高特征保真度”之间取得平衡。为适应实际可用的几十个量子比特，多数混合模型不得不对原始遥感图像进行激进的下采样裁剪或特征截断，这一预处理过程不可避免地导致了高频空间细节(如边缘信息)与微小目标线索(如车辆、船只)的流失，限制了模型在像素级任务中的应用上限[23]。

其次，“贫瘠高原(Barren Plateaus)”现象与硬件噪声构成联合优化障碍。研究表明，在变分量子算法中，随着量子比特数量和未引入先验结构的参数化线路深度的增加，目标函数梯度的方差会呈现出指数级衰减的数学性质，即进入梯度几近为零的“贫瘠高原”效应[24]。此外，真实 NISQ 硬件中普遍存在的热弛豫噪声、退相干噪声以及门操作串扰等物理误差，会进一步抹平损失函数的能量景观，诱发噪声驱动的梯度消失[25]。这意味着在处理复杂度较高的遥感多分类任务时，未经特定拓扑设计的量子架构会导致模型完全无法收敛。

再次，异构特征的协同融合机制存在缺失。在现有的混合架构中，计算逻辑多是串行的：依赖经典网络提取粗粒度特征，再将压缩后的向量单向传输给量子电路捕捉高阶统计相关性。然而，遥感场景通常包含平原、城市、森林等不同纹理复杂度的区域，量子算子与经典算子在处理不同频率信息时缺乏动态平衡与反馈调节机制。这种单一的单向级联结构可能引发跨域特征对齐时的“信息冲突”，难以充分释放异构算力的协同潜能。

6. 趋势与展望

针对前述制约因素与遥感领域的应用痛点，量子深度学习在地球观测数据智能化解译中的演进将遵循渐进式路径。基于此，本文提出如下阶段性研究路线图：

6.1. 近期探索：特定拓扑的张量网络拟设与量子迁移

在 NISQ 设备受限的当下，盲目增加量子线路深度易导致失效。近期的研究重点应聚焦于设计与遥感空间先验相匹配的量子拟设(Ansatz)。例如，引入具有局部纠缠特性的树状张量网络(Tree Tensor Networks, TTN)或多尺度纠缠重整化拟设(MERA) [26]。这类架构能够以对数级线路深度捕捉遥感图像中地物的多尺度空间相关性。此外，以预训练的大规模经典视觉模型为底座，仅在特定下游任务中接入浅层 PQC 进行量子迁移学习[27]，将是突破高分辨率图像处理瓶颈的可行方案。

6.2. 中期突破：面向遥感特性的量子架构搜索与误差缓解

随着硬件扩展，中期的研究有望通过量子架构搜索(QNAS)自动化完成网络设计[28]。研究者需着手开发针对遥感数据特性的 QNAS 搜索空间，并设计兼顾分类精度、线路深度与梯度方差(规避“贫瘠高原”)的复合奖励函数。同时，硬件感知级的误差缓解技术(如概率误差对消，PEC)将被集成至反向传播中，以提升模型在真实噪声 QPU 上的推理鲁棒性。

6.3. 远期展望：容错量子计算(FTQC)时代的规模化应用

当具备全面量子纠错能力的容错量子计算机(FTQC)成熟时, 纯量子算法将取代现有的启发式变分架构。大尺度、长时序的全球气候监测数据与动态地表演化特征, 能够被直接编码入深层量子态中进行测算。混合量子深度学习有望成为多模态地球观测数据解译中一种具备参数效能潜力的补充计算范式。

参考文献

- [1] Zhu, X.X., Tuia, D., Mou, L., Xia, G., Zhang, L., Xu, F., *et al.* (2017) Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geoscience and Remote Sensing Magazine*, **5**, 8-36. <https://doi.org/10.1109/mgrs.2017.2762307>
- [2] 程赓, 郭雷. 遥感图像复杂场景理解的深度学习方法与挑战[J]. 自动化学报, 2021, 47(11): 2539-2559.
- [3] Cheng, G., Xie, X., Han, J., Guo, L. and Xia, G. (2020) Remote Sensing Image Scene Classification Meets Deep Learning: Challenges, Methods, Benchmarks, and Opportunities. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **13**, 3735-3756. <https://doi.org/10.1109/jstars.2020.3005403>
- [4] Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N. and Lloyd, S. (2017) Quantum Machine Learning. *Nature*, **549**, 195-202. <https://doi.org/10.1038/nature23474>
- [5] Schuld, M. and Killoran, N. (2019) Quantum Machine Learning in Feature Hilbert Spaces. *Physical Review Letters*, **122**, Article 040504. <https://doi.org/10.1103/physrevlett.122.040504>
- [6] Preskill, J. (2018) Quantum Computing in the NISQ Era and beyond. *Quantum*, **2**, Article 79. <https://doi.org/10.22331/q-2018-08-06-79>
- [7] McClean, J.R., Romero, J., Babbush, R. and Aspuru-Guzik, A. (2016) The Theory of Variational Hybrid Quantum-Classical Algorithms. *New Journal of Physics*, **18**, Article 023023. <https://doi.org/10.1088/1367-2630/18/2/023023>
- [8] Liu, J., Lim, K.H., Wood, K.L., Huang, W., Guo, C. and Huang, H. (2021) Hybrid Quantum-Classical Convolutional Neural Networks. *Science China Physics, Mechanics & Astronomy*, **64**, Article No. 290311. <https://doi.org/10.1007/s11433-021-1734-3>
- [9] Benedetti, M., Lloyd, E., Sack, S. and Fiorentini, M. (2019) Parameterized Quantum Circuits as Machine Learning Models. *Quantum Science and Technology*, **4**, Article 043001. <https://doi.org/10.1088/2058-9565/ab4eb5>
- [10] LaRose, R. and Coyle, B. (2020) Robust Data Encodings for Quantum Classifiers. *Physical Review A*, **102**, Article 032420. <https://doi.org/10.1103/physreva.102.032420>
- [11] Cavallaro, G., Willsch, D., Willsch, M., Michielsen, K. and Riedel, M. (2020) Approaching Remote Sensing Image Classification with Ensembles of Support Vector Machines on the D-Wave Quantum Annealer. 2020 *IEEE International Geoscience and Remote Sensing Symposium*, Waikoloa, 26 September-2 October 2020, 1973-1976. <https://doi.org/10.1109/igarss39084.2020.9323544>
- [12] Cong, I., Choi, S. and Lukin, M.D. (2019) Quantum Convolutional Neural Networks. *Nature Physics*, **15**, 1273-1278. <https://doi.org/10.1038/s41567-019-0648-8>
- [13] Sebastianelli, A., Zaidenberg, D.A., Spiller, D., Le Saux, B. and Ullo, S. (2022) On Circuit-Based Hybrid Quantum Neural Networks for Remote Sensing Imagery Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **15**, 565-580. <https://doi.org/10.1109/jstars.2021.3134785>
- [14] Fan, F., Shi, Y., Guggemos, T. and Zhu, X.X. (2024) Hybrid Quantum-Classical Convolutional Neural Network Model for Image Classification. *IEEE Transactions on Neural Networks and Learning Systems*, **35**, 18145-18159. <https://doi.org/10.1109/tnnls.2023.3312170>
- [15] Liang, Y., Peng, W., Zheng, Z., Silvén, O. and Zhao, G. (2021) A Hybrid Quantum-Classical Neural Network with Deep Residual Learning. *Neural Networks*, **143**, 133-147. <https://doi.org/10.1016/j.neunet.2021.05.028>
- [16] Zhao, R.X., Shi, J. and Li, X. (2024) QKSAN: A Quantum Kernel Self-Attention Network. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **46**, 10184-10195. <https://doi.org/10.1109/tpami.2024.3434974>
- [17] Otgonbaatar, S. and Datcu, M. (2021) A Quantum Annealer for Subset Feature Selection and the Classification of Hyperspectral Images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **14**, 7057-7065. <https://doi.org/10.1109/jstars.2021.3095377>
- [18] Otgonbaatar, S. and Datcu, M. (2022) Natural Embedding of the Stokes Parameters of Polarimetric Synthetic Aperture Radar Images in a Gate-Based Quantum Computer. *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-8. <https://doi.org/10.1109/tgrs.2021.3110056>
- [19] Zoufal, C., Lucchi, A. and Woerner, S. (2019) Quantum Generative Adversarial Networks for Learning and Loading

- Random Distributions. *npj Quantum Information*, **5**, Article No. 103. <https://doi.org/10.1038/s41534-019-0223-2>
- [20] Huang, H.L., Du, Y., Gong, M., Zhao, Y., Wu, Y., Wang, C., *et al.* (2021) Experimental Quantum Generative Adversarial Networks for Image Generation. *Physical Review Applied*, **16**, Article 024051. <https://doi.org/10.1103/physrevapplied.16.024051>
- [21] Havlíček, V., Córcoles, A.D., Temme, K., Harrow, A.W., Kandala, A., Chow, J.M., *et al.* (2019) Supervised Learning with Quantum-Enhanced Feature Spaces. *Nature*, **567**, 209-212. <https://doi.org/10.1038/s41586-019-0980-2>
- [22] Caro, M.C., Huang, H., Cerezo, M., Sharma, K., Sornborger, A., Cincio, L., *et al.* (2022) Generalization in Quantum Machine Learning from Few Training Data. *Nature Communications*, **13**, Article No. 4919. <https://doi.org/10.1038/s41467-022-32550-3>
- [23] Le, P.Q., Dong, F. and Hirota, K. (2011) A Flexible Representation of Quantum Images for Polynomial Preparation, Image Compression, and Processing Operations. *Quantum Information Processing*, **10**, 63-84. <https://doi.org/10.1007/s11128-010-0177-y>
- [24] McClean, J.R., Boixo, S., Smelyanskiy, V.N., Babbush, R. and Neven, H. (2018) Barren Plateaus in Quantum Neural Network Training Landscapes. *Nature Communications*, **9**, Article No. 4812. <https://doi.org/10.1038/s41467-018-07090-4>
- [25] Wang, S., Fontana, E., Cerezo, M., Sharma, K., Sone, A., Cincio, L., *et al.* (2021) Noise-Induced Barren Plateaus in Variational Quantum Algorithms. *Nature Communications*, **12**, Article No. 6961. <https://doi.org/10.1038/s41467-021-27045-6>
- [26] Grant, E., Benedetti, M., Cao, S., Hallam, A., Lockhart, J., Stojevic, V., *et al.* (2018) Hierarchical Quantum Classifiers. *NPJ Quantum Information*, **4**, Article No. 65. <https://doi.org/10.1038/s41534-018-0116-9>
- [27] Mari, A., Bromley, T.R., Izaac, J., Schuld, M. and Killoran, N. (2020) Transfer Learning in Hybrid Classical-Quantum Neural Networks. *Quantum*, **4**, 340. <https://doi.org/10.22331/q-2020-10-09-340>
- [28] Du, Y., Huang, T., You, S., Hsieh, M. and Tao, D. (2022) Quantum Circuit Architecture Search for Variational Quantum Algorithms. *npj Quantum Information*, **8**, Article No. 62. <https://doi.org/10.1038/s41534-022-00570-y>