

DISTILLAZIONE DELLA CONOSCENZA QUANTISTICA

Simone Piperno, Giacomo Vittori, Antonello Rosato, Massimo Panella

Dipartimento di Ingegneria dell'Informazione, Elettronica e Telecomunicazioni (DIET)
Università degli Studi di Roma "La Sapienza"
Via Eudossiana 18, 00184 Roma

La *Knowledge Distillation* (KD) è una tecnica consolidata nel machine learning classico, dove un modello più piccolo (*student*) imita il comportamento di un modello più complesso (*teacher*) per migliorare efficienza e prestazioni [1, 2]. Con l'avvento del Quantum Machine Learning (QML), l'estensione della KD a modelli quantistici rappresenta una frontiera promettente per superare le limitazioni degli attuali dispositivi quantistici Noisy Intermediate-Scale Quantum (NISQ) [3]. Studi preliminari hanno esplorato l'uso di reti classiche pre-addestrate come estrattori di feature per circuiti quantistici [4, 5], dimostrando miglioramenti nell'accuratezza su dataset come MNIST e CIFAR-10. In [4] viene evidenziata l'efficacia della codifica in ampiezza e di tecniche di riduzione dimensionale classica prima dell'elaborazione quantistica. Un approccio alternativo, proposto in [5], combina Multi-Layer Perceptrons (MLPs) classici con Quantum Neural Networks (QNNs) per stabilizzare l'addestramento. Tuttavia, questi lavori si concentrano su architetture ibride, trascurando il potenziale della KD per modelli completamente quantistici.

La presente ricerca si è posta l'obiettivo di colmare questa lacuna proponendo un framework di Classical-to-Quantum Knowledge Distillation (C2Q KD) in cui viene confrontato sistematicamente l'impatto della KD in entrambi i contesti, con risultati che evidenziano dei vantaggi per le architetture completamente quantistiche [6, 7]. Questo approccio mira a trasferire la conoscenza "oscura" (*dark knowledge*), che include le relazioni inter-classe rivelate dalle distribuzioni di probabilità del teacher, alle architetture quantistiche, con il potenziale di migliorare le prestazioni e ridurre i costi di addestramento. Sono state investigate le performances di due architetture principali. Il primo è un modello completamente quantistico (MCQ) che utilizza esclusivamente circuiti quantistici variazionali, riportato in Fig. 1; sfrutta la codifica in ampiezza per codificare i dati e misurazioni dirette per la classificazione. Il secondo è il modello ibrido (MI) in Fig. 2, il quale combina un circuito quantistico variazionale (VQC) con un MLP classico per la classificazione finale. Entrambe le architetture sono state valutate su un sottoinsieme del dataset MNIST (cifre 0-6), con configurazioni diverse per numero di strati e qubits. L'architettura quantistica trae ispirazione dal *circuit-centric classifier*.

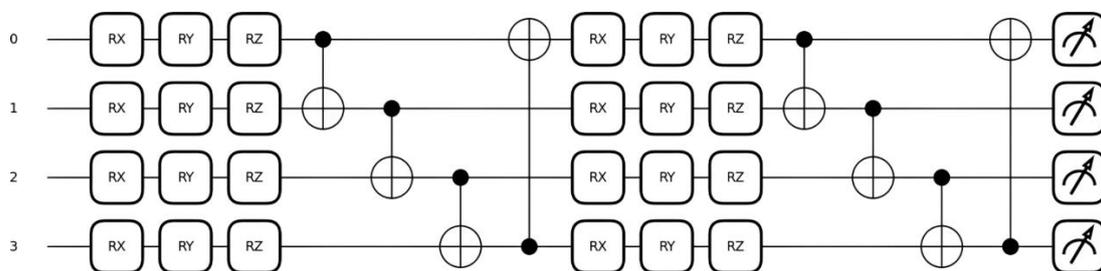


Figura 1 - Modello completamente Quantistico (2 layer) in cui ogni layer include gate rotazionali parametrici RX, RY, RZ e gate CNOT per generare entanglement.

I test sono stati condotti con due setup differenti:

- Setup 1: addestramento su 60,000 campioni per 200 epoche con *early stopping*; le architetture addestrate con KD, invece, per sole 3 epoche;
- Setup 2: addestramento su 10,000 campioni per 100 epoche con *early stopping*.

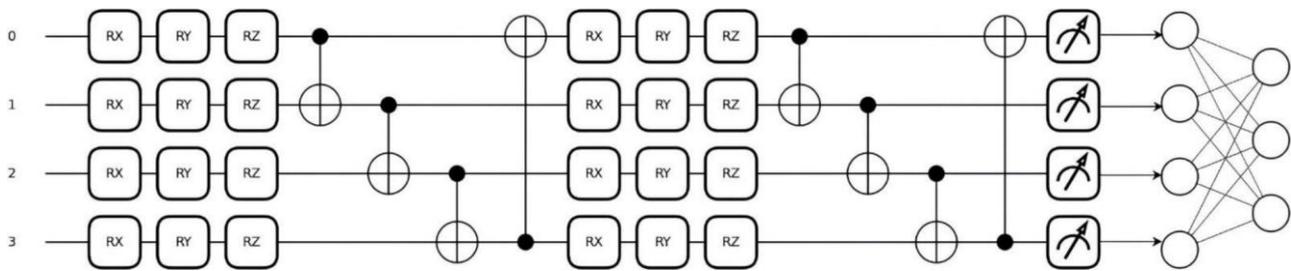


Figura 2 - Modello Ibrido (2 layer) con MLP per far combaciare l'output con la dimensione di 3 classi.

Nel Setup 1 la KD ha mostrato vantaggi in termini di efficienza per i modelli completamente quantistici, raggiungendo prestazioni simili con un numero significativamente inferiore di epoche di addestramento. Nel Setup 2, la KD offre comunque benefici, soprattutto nei modelli quantistici più semplici, suggerendo che la conoscenza distillata può trasmettere informazioni difficilmente ottenibili dai soli dati di addestramento. Per le architetture ibride, la relazione tra KD e i modelli senza distillazione cambia nei due setup. Sebbene nel Setup 1 i modelli standalone abbiano ottenuto prestazioni migliori, nel Setup 2 i modelli KD superano generalmente quelli standalone se addestrati nelle stesse condizioni.

Questa ricerca indica che la distillazione può avere un effetto di regolarizzazione utile in contesti con dati limitati, aiutando i modelli ibridi a generalizzare meglio. Lo studio dimostra che la C2Q KD è particolarmente efficace per modelli quantistici puri, mitigando le loro limitazioni intrinseche. Le architetture ibride, sebbene meno sensibili alla KD, rimangono competitive grazie alla loro flessibilità. Prospettive future includono esplorare tecniche di KD alternative, come ad esempio *feature-based* o *relation-based* ed estendere la valutazione a dataset più complessi.

Riferimenti bibliografici

- [1] G. Hinton, O. Vinyals, and J. Dean, "Distilling the knowledge in a neural network," *arXiv preprint arXiv:1503.02531*, 2015.
- [2] C. Hu, X. Li, D. Liu, H. Wu, X. Chen, J. Wang, and X. Liu, "Teacher-student architecture for knowledge distillation: A survey," *arXiv preprint arXiv:2308.04268*, 2023.
- [3] J. Preskill, "Quantum Computing in the NISQ era and beyond", *Quantum*, vol. 2, p. 79, 2018.
- [4] M. J. Hasan and M. Mahdy, "Bridging classical and quantum machine learning: Knowledge transfer from classical to quantum neural networks using knowledge distillation," *arXiv preprint arXiv:2311.13810*, 2023.
- [5] M. Li, L. Fan, A. Cummings, X. Zhang, M. Pan, and Z. Han, "Hybrid quantum classical machine learning with knowledge distillation," in *ICC 2024-IEEE International Conference on Communications*. IEEE, pp. 1139–1144, 2024.
- [6] S. Piperno, A. Ceschini, S.Y. Chang, M. Grossi, S. Vallecorsa, and M. Panella, "A Study on Quantum Graph Neural Networks Applied to Molecular Physics," *Physica Scripta*, 2025 (in stampa).
- [7] S. Piperno, G. Vittori, D. Windridge, A. Rosato, and M. Panella, "Classical to Quantum Knowledge Distillation: a Study on the Impact of Hybridization", *Proc. of International Joint Conference on Neural Networks (IJCNN 2025)*, Roma, Italia, 30 giugno-5 luglio 2025.