



Universiteit  
Leiden

The Netherlands

## Quantum machine learning: on the design, trainability and noise-robustness of near-term algorithms

Skolik, A.

### Citation

Skolik, A. (2023, December 7). *Quantum machine learning: on the design, trainability and noise-robustness of near-term algorithms*. Retrieved from <https://hdl.handle.net/1887/3666138>

Version: Publisher's Version

License: [Licence agreement concerning inclusion of doctoral thesis in the Institutional Repository of the University of Leiden](#)

Downloaded from: <https://hdl.handle.net/1887/3666138>

**Note:** To cite this publication please use the final published version (if applicable).

---

## Samenvatting

Variational quantum machine learning modellen worden vaak gezien als het quantum analogoog van klassieke neurale netwerken vanwege de gelijkenis in hun trainingsprocedure. Ze worden daarom ook wel quantum neurale netwerken genoemd. In tegenstelling tot hun klassieke tegenhangers zijn er echter nog veel open vragen over hoe trainbare en performante quantum neurale netwerken ontwerpen kunnen worden. Bijvoorbeeld, hoe kan je standaard data in een quantum model representeren; hoe moeten operaties in de circuits gestructureerd worden; of hoe kunnen optimaliseringsproblemen, die specifiek voor quantum circuits zijn, verhinderd worden. Net als klassieke hardware een game changer was voor de ontwikkeling van machine learning, kan een verbetering van quantum hardware een grote invloed hebben op de ontwikkelen van variational quantum machine learning modellen. Het is daarom van groot belang een begrip te ontwikkelen van hoe deze modellen met succes getrained kunnen worden. Dit proefschrift draagt bij aan dit begrip door zulke aspecten van variational quantum machine learning modellen te bestuderen.

We beginnen met een inleiding tot de quantum computing, machine learning en hun interactie in hoofdstukken 2 en 3. In hoofdstuk 4 bestuderen we hoe een fundamenteel probleem in het trainen van variational quantum circuits, namelijk het ontstaan van „barren plateaus” in de traininglandschappen, kan worden aangepakt door een bestaande leermethoden, die dan tot een vergroting van quantum modellen gebruikt kan worden. Hiertoe bieden we een trainingsprocedure dat het probleem van „barren plateaus” voor specifieke gevallen verlicht en vergelijken we het met standaard trainingsprocedures uit de literatuur.

Hoewel dit type trainingsprocedures in principe voor alle soorten machine learning kan worden gebruikt, richten we onze aandacht in de volgende hoofdstukken specifiek op een bepaald type, namelijk op reinforcement learning (RL). Allereerst

bestuderen we in hoofdstuk 5 hoe de architecturale keuzes voor een quantumagent gebaseerd op een parameterized quantum circuit (PQC) de prestaties beïnvloeden in twee benchmarks uit de RL-literatuur, waarbij we specifiek kijken naar de vraag hoe gegevens te coderen zijn in, en informatie te lezen is uit het quantummodel. Daarnaast stellen we een theoretische scheiding vast tussen klassieke- en quantummodellen voor het specifieke type RL-algoritme dat we gebruiken, en vergelijken het quantummodel empirisch met een klassiek neuraal netwerk. Naast de vragen hoe gegevens te coderen en te lezen uit een PQC, is de derde belangrijke vraag hoe de structuur van een variational quantum machine learning model ontworpen moet worden. Daarvoor gaan we in hoofdstuk 6 verder met het onderzoeken van deze vraag en introduceren we een structuur die is aangepast aan een specifiek type input, namelijk aan gewogen grafen. Hiervoor nemen we inspiratie uit het gebied van geometrical deep learning, en ontwerpen we een PQC dat een belangrijke symmetrie behoudt in graaf-gebaseerde input. We bestuderen de expressiviteit van dit type circuit analytisch, en vergelijken het daarna numeriek met structuren die niet aangepast zijn aan de specifieke input. Ten slotte is een andere belangrijk overweging bij het bestuderen van algoritmen voor het NISQ-tijdperk hoe de gegeven trainingsprocedures en modellen worden beïnvloed door de ruis veroorzaakt door de quantumhardware. In hoofdstuk 7 bestuderen we dit voor twee van de variational RL-paradigma's uit recente literatuur. We onderzoeken analytisch en numeriek hoe verschillende soorten fouten, namelijk coherente, incoherente en op metingen gebaseerde fouten, de trainingsprestaties van variational RL-algoritmen en de robuustheid van de geleerde strategie beïnvloeden. In het bijzonder bevat dit onderzoek een evaluatie van de prestaties van de modellen die we in hoofdstuk 5 en hoofdstuk 6 hebben ingevoerd onder verschillende soorten ruis die verwacht worden aanwezig te zijn op quantumhardware.

Met bovenstaande hoopt dit proefschrift bij te dragen aan het opbouwen van een basis van kennis over hoe variational quantum machine learning modellen met succes opgeleid kunnen worden, in de hoop dat, zoals bij klassieke machine learning, deze kennis ooit, als de quantumhardware voldoende performant is geworden, zal helpen bij de praktische bruikbaarheid van dit soorten algoritmen.