



Universiteit
Leiden
The Netherlands

Computational speedups and learning separations in quantum machine learning

Gyurik, C.

Citation

Gyurik, C. (2024, April 4). *Computational speedups and learning separations in quantum machine learning*. Retrieved from <https://hdl.handle.net/1887/3731364>

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/1887/3731364>

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

Samenvatting

In dit proefschrift is onderzocht hoe quantumcomputers kunnen bijdragen aan machine learning, hetgeen valt binnen het vakgebied Quantum Machine Learning. Dit vakgebied belooft nieuwe perspectieven en methoden voor het oplossen van complexe problemen in machine learning door gebruik te maken van de unieke mogelijkheden van quantumcomputers. Quantumcomputers verschillen fundamenteel van klassieke computers door hun gebruik van kwantummechanica, wat leidt tot unieke rekenmogelijkheden. In tegenstelling tot klassieke bits, die ofwel 0 of 1 kunnen zijn, maken quantumcomputers gebruik van qubits die dankzij “superpositie” zowel 0 als 1 tegelijk kunnen zijn. Bovendien stellen “verstrengelingen” quantumcomputers in staat om qubits in een onderling afhankelijke toestand te brengen, wat complexe parallele berekeningen mogelijk maakt. Binnen het onderzoeksgebied quantum machine learning heeft dit proefschrift verschillende voorstellen onderzocht met betrekking tot manieren waarop quantumcomputers delen van machine learning kunnen verbeteren.

Het eerste voorstel dat dit proefschrift heeft onderzocht, was het verkennen van de toepassingen van quantum computers in topologische data-analyse. Topologische data-analyse is een innovatieve benadering om robuuste eigenschappen uit datasets te halen door de inherente “vorm” ervan te begrijpen. Binnen dit kader heeft dit proefschrift zich specifiek gericht op quantumalgoritmen voor lineaire algebra, met als doel te begrijpen of ze superpolynomiale versnellingen kunnen bieden ten opzichte van klassieke methoden. De resultaten in dit proefschrift hebben aangetoond dat bestaande quantumalgoritmes voor topologische data-analyse, samen met een aantal nieuwe algoritmes die in dit proefschrift zijn ontwikkeld (met toepassingen in numerieke lineaire algebra, machine learning en complexe netwerkanalyse), problemen oplossen die klassiek gezien niet efficiënt oplosbaar zijn volgens wijdverspreide aannames in de complexiteitstheorie. Concreet hebben deze resultaten laten zien dat de versnelling die de methoden van het quantumalgoritme voor topologische data-analyse bieden, bestand is tegen het ontwikkelen van eventuele snellere klassieke algoritmes. Deze resultaten geven inzicht in de potentiële kracht van quantumcomputers bij het oplossen van complexe problemen in topologische data-analyse, machine learning en netwerkanalyse.

Een ander aspect van dit proefschrift is het onderzoek naar structural risk minimization in het kader van quantum machine learning-modellen. Structural Risk Minimization (SRM) is een principe in machine learning dat de balans zoekt tussen modelcomplexiteit en prestaties op nieuwe data. Het houdt in dat je een model kiest uit een bepaalde familie van modellen, waarbij je een evenwicht zoekt tussen

trainingsfout (hoe goed het model past bij de trainingsdata) en een complexiteitsterm (die té complexe modellen bestraft). Hierbij lag de focus op het begrijpen van de invloed van bepaalde ontwerpkeuzes in machine learning modellen gebaseerd op geparametriseerde quantumcircuits. Kortweg, een geparametriseerd quantumcircuit kun je zien als een quantumvariant van een neuraal netwerk, waarbij men een aantal qubits manipuleert op een manier die afhangt van enkele parameters, en waarbij je op zoek gaat naar de juiste parameters voor het probleem dat je probeert op te lossen. Het onderzoek in dit proefschrift vroeg zich af of we belangrijke instellingen binnen nieuwe quantum-machine learning-modellen gebaseerd op parameteriseerbare quantumcircuits kunnen identificeren, die zowel complexiteitstermen als de trainingsfout beïnvloeden, wat cruciaal is voor het succesvol implementeren van SRM. In het bijzonder heeft dit proefschrift gedemonstreerd hoe we nieuwe quantum-machineleermodellen kunnen construeren met gunstige prestatiegaranties op basis van het principe van SRM. Deze inzichten kunnen bijdragen aan het optimaliseren van quantum machine learning-modellen, waardoor ze beter presteren.

Het volgende onderwerp dat dit proefschrift onderzocht, was hoe quantumcomputers kunnen helpen bij “reinforcement learning”. Reinforcement learning draait om leren door interactie om een bepaald doel te bereiken. Dit wordt meestal gemodelleerd door de interactie tussen een “agent” (de leerling) en een “omgeving”. De agent neemt voortdurend acties, en na elke actie reageert de omgeving door de agent een “beloning” te geven. Het doel van de agent is om deze beloningen in de loop van de tijd te maximaliseren. Binnen de reinforcement learning zijn er in dit proefschrift quantummodellen geïntroduceerd die gebaseerd zijn op geparametriseerde quantumcircuits. Opmerkelijk was dat deze modellen vergelijkbare prestaties konden leveren als traditionele klassieke model (zoals diepe neurale netwerken), terwijl ze in bepaalde scenario’s superieure prestaties vertoonden. Deze ontdekking suggereert dat quantummodellen een krachtig instrument kunnen zijn bij het oplossen van complexe problemen in reinforcement learning.

Het laatste deel van het onderzoek in dit proefschrift betrof de identificatie van leertaken binnen de “computational learning theory” waarvoor quantumleeralgoritmen exponentiële voordelen hebben ten opzichte van klassieke algoritmen. Computational learning theory is een wiskundig framework geïntroduceerd in de jaren ’90 met het doel formele argumenten te verschaffen over waarom en hoe machine learning in de praktijk succesvol kan zijn. Eerst dook dit proefschrift diep in de details om precies te definiëren wat het betekent dat een quantum-leerling een exponentieel voordeel heeft ten opzichte van zijn klassieke tegenhanger. Daarna onderzocht het eerdere gevallen van exponentiele voordelen, waarbij we de precieze bron van klassieke complexiteit en het voordeel van quantum modellen identificeerden. Ten slotte onderzocht het de algemene opvatting dat quantum machine learning het beste presteert in scenario’s met data gegenereerd door quantum-processen. Hierbij hebben we een kader opgesteld waarin elk probleem met data gegenereerd door quantum-processen kan leiden tot een exponentieel quantumvoordeel. Dit opent deuren naar de toepassing van quantum computing in specifieke scenario’s waarin klassieke algoritmen tekortschieten.

Samenvattend biedt dit proefschrift een verkenning van Quantum Machine Learning, waarbij de unieke capaciteiten van quantumcomputers worden toegepast op uiteenlopende domeinen binnen machine learning. Van de toepassing van quantum

malgoritmen in topologische data-analyse tot het begrijpen van de invloed van ontwerpkeuzes op structural risk minimization, en de introductie van quantummodellen in reinforcement learning. Het onderzoek sluit af met een blik op leertaken in de computational learning theory, waar quantumleeralgoritmen exponentiële voordelen kunnen bieden. In zijn geheel draagt dit proefschrift bij aan het begrip van de veelbelovende rol van quantumcomputers in het oplossen van complexe problemen binnen machine learning.