

Streszczenie

Rozwój skalowalnych komputerów kwantowych wymaga skutecznych metod charakteryzowania, modelowania i sterowania złożonymi układami kwantowymi na podstawie danych dostępnych eksperymentalnie. W układach ciała stałego dane te są często jedynie pośrednio związane z poszukiwanymi wielkościami fizycznymi. Wyniki pomiarów tomografii kwantowej wymagają odpowiedniego przekształcenia w celu odtworzenia stanu kwantowego, natomiast widma transportowe należy analitycznie interpretować w celu oszacowania parametrów hamiltonianu lub faz topologicznych. W niniejszej rozprawie zbadano, w jaki sposób metody uczenia maszynowego mogą pomóc uprościć ten proces, w szczególności w analizie stanów kwantowych, interpretacji pomiarów oraz sterowaniu układami kwantowymi ciała stałego na podstawie fizycznej informacji.

Pierwsza część rozprawy poświęcona jest identyfikacji korelacji kwantowych. Opracowano nienadzorowane podejście oparte na sieciach neuronowych, które uczą się struktury trzy-kubitowych stanów separowalnych i identyfikują stany skorelowane kwantowo jako anomalie. Podejście to rozwinęto następnie z wykorzystaniem nadzorowanych i częściowo nadzorowanych syjamskich sieci neuronowych. W procesie treningu sieci nauczono symetrii zachowujących splątanie, takich jak lokalne transformacje unitarne oraz permutacje kubitów, co pozwoliło na zwiększenie skuteczności wykrywania splątania oraz poprawienie zdolności modeli do generalizacji poza dane treningowe.

Druga część rozprawy koncentruje się na analizie realistycznych reprezentacji danych pomiarowych. Sieci neuronowe oraz losowe lasy decyzyjne zostały wykorzystane do identyfikacji splątania kwantowego bezpośrednio z danych tomograficznych. Analiza wykazała, że różne klasy modeli mogą opierać swoje predykcje na znacząco odmiennych danych pomiarowych. W dalszej kolejności opracowano metody tomografii kwantowej wspomaganej uczeniem maszynowym przy informacyjnie niepełnej liczbie pomiarów. Podstawowe modele sieci neuronowych zostały wykorzystane do poprawy rekonstrukcji otrzymywanej metodą macierzy pseudoodwrotnej, a bardziej zaawansowane sieci rekurencyjne użyto do jednoczesnej rekonstrukcji stanów kwantowych i optymalizacji kolejności wykonywania pomiarów.

Ostatnia część rozprawy dotyczy symulatorów kwantowych opartych na układach ciała stałego oraz platform topologicznych. Na podstawie map przewodnictwa sieć neuronowa informowaną fizyką miała za zadanie automatycznie dostosować parametry hamiltonianu opartego na kropkach kwantowych w celu realizacji modów zerowych Majorany. W tym celu podczas uczenia zastosowano różniczkowalną quasi-metrykę do oceny jakości powstałych modów. Ponadto wytrenowano autoenkoder przeznaczony do przewidywania parametrów hamiltonianu bezpośrednio z pomiarów transportowych. W tym podejściu enkoder przewiduje efektywne parametry hamiltonianu, podczas gdy fizyczny dekodek, oparty na formalizmie macierzy rozpraszania, narzuca model fizyczny opisujący badany układ.

Wyniki przedstawione w rozprawie pokazują, że połączenie uczenia opartego na danych z uwzględnieniem dodatkowych ograniczeń wynikających z praw fizyki może zwiększać dokładność, interpretowalność oraz zdolność modeli do generalizacji w analizie i sterowaniu układami kwantowymi. Wnioski wskazują, że uczenie maszynowe informowane fizyką może służyć jako ogólna metoda do identyfikacji korelacji kwantowych, rekonstrukcji stanów z niepełnych danych pomiarowych, wyznaczania efektywnych hamiltonianów oraz sterowania układami kwantowymi w celu osiągnięcia pożądanego zakresu parametrów.