

Kratek pregled kvantnega strojnega učenja



BOJAN ŽUNKOVIČ

→ **Kvantno strojno učenje je interdisciplinarno raziskovalno področje. Da bi ga lahko razumeli, se bomo posebej posvetili najprej strojnemu učenju in nato kvantnemu računanju. Šele nato bomo pogledali, kako sta področji prepleteni in zakaj je smiselno govoriti o kvantnem strojnem učenju.**

Uvod

Strojno učenje je proučevanje algoritmov za opisovanje pojavov na podlagi podatkov. Gre torej za nabor algoritmov, s pomočjo katerih lahko iz podatkov izluščimo uporabno znanje v obliki verjetnostnih porazdelitev, relacij, pravil ali enačb. Osnovna lastnost algoritmov strojnega učenja je neodvisnost od interpretacije podatkov, zato je domena njihove uporabe zelo široka. Algoritmi strojnega učenja so postali nepogrešljivo orodje v industriji, logistiki, ekonomiji, medicini in farmaciji, kjer se uporabljajo za medicinsko diagnostiko, zaznavanje prevar, za določanje priporočil, prevajanje, razpoznavanje govora in pisave, klasifikacijo tekstov in slik, za nadzor dinamičnih procesov in sistemov, igranje iger, avtonomno vožnjo. Najpomembnejši prednosti strojnega učenja v primerjavi z drugimi pristopi sta, da za uspešno rešitev problema le-to ne potrebuje poznavanja podrobnosti in da se dobljena rešitev izboljšuje s količino podatkov. Poleg zmogljivejših računalnikov je ravno hitro naraščanje količine podatkov tisto, ki je omogočilo zadnji razcvet strojnega učenja. Uspeh slednjega pa je še povečal potrebo po zmogljivejših računalnikih, kar je tudi najpomembnejši motiv za pospešen razvoj kvantnih računalnikov.

Čeprav bi lahko trdili, da so vsi osebni računalniki kvantni, je razlikovanje med klasičnimi računalniki in kvantnimi računalniki upravičeno. Bistvena razlika je v tem, da klasični računalniki operirajo s

klasično informacijo, zakodirano v niz ničel in enic, medtem ko kvantni računalniki manipulirajo osnovne kvantnomehanske objekte, valovne funkcije. Prednost kvantnih računalnikov temelji na dejstvu, da je opis valovnih funkcij s pomočjo klasičnih računalnikov zelo zahteven. Najpomembnejša naloga teoretičnega kvantnega računalništva je torej iskanje načinov izražanja zahtevnih klasičnih operacij s pomočjo dinamike valovnih funkcij, ki jo lahko simuliramo s kvantnim računalnikom. Najznamenitejši primer klasično zahtevne operacije, za katero obstaja učinkovitejši kvantni algoritem, je faktorizacija števil. Toda ta, kot tudi drugi znani kvantni algoritmi, potrebuje zmogljiv kvantni računalnik, ki bi mu uspelo manipulirati valovno funkcijo dovolj dolgo, kar trenutno še ni izvedljivo. Težava pri obvladovanju valovne funkcije je, da mora biti dovolj dobro izolirana od okolice, torej samih naprav, ki jo spreminjajo in na koncu izvedejo meritev. Vsak šum, ki se pojavi zaradi interakcije z okolico, se zelo hitro razširi in pokvari želeni algoritem. Trenutne naprave niso primerne za znane kvantne algoritme, ki potrebujejo veliko kvantnih operacij. Ravno nasprotno je s strojnem učenjem, ki je prilagojeno za delo z velikimi količinami zašumljenih podatkov. Algoritmi strojnega učenja tako predstavljajo naravno (ustrezno) izbiro za uporabo trenutnih kvantnih računalnikov.

Vzajemna uporabnost strojnega učenja in kvantnega računanja je vzpodbudila prepletenost obeh področij. Govorimo ne le o uporabi kvantnih računalnikov za pohitritev klasičnih algoritmov strojnega učenja in prenosa slednjih v kvantno domeno, ampak o splošni razširitvi obzorja obeh področij v smislu uporabe teoretičnih orodij in zastavljanja novih vprašanj. Raziskovalno področje kvantnega strojnega učenja lahko glede na algoritem (klasični ali kvantni) in podatke (klasični ali kvantni) ločimo na štiri podpodročja, kot prikazuje slika 1.





		Algoritem	
		Klasični (C)	Kvantni (Q)
Podatki	Klasični (C)	CC	CQ
	Kvantni (Q)	QC	QQ

SLIKA 1.

Razdelitev področja kvantnega strojnega učenja glede na algoritem in podatke

Opisovanje klasičnih podatkov s klasičnimi algoritmi spada v področje kvantnega strojnega učenja. Sem uvrstimo raziskave, ki uporabljajo metode z enega področja za reševanje problemov na drugem področju. Metode za kompresijo kvantnih stanj lahko npr. uporabimo tudi za kompresijo globokih nevronske mreže, kar ima zelo veliko praktično vrednost zaradi prenosa globokih nevronske mreže na računsko manj zmožljive naprave. Iste metode se lahko uporabljajo tudi za reševanje tipičnih problemov strojnega učenja, kot so klasifikacija, generiranje novih podatkov ali prevajanje. Po drugi strani pa predstavljajo klasične metode strojnega učenja, kot so Boltzmanovi stroji, nevronske mreže in avto-regresivni modeli, nov variacijski pristop k simulaciji večdelčnih kvantnih sistemov, ki omogoča učinkovit opis visoko prepletenih kvantnih stanj. Modeli strojnega učenja so uporabni tudi pri zaznavanju faznih prehodov. V prvo podpodročje kvantnega strojnega učenja lahko uvrstimo tudi klasifikacijo ekspresivnosti nevronske mreže s pomočjo metod za klasifikacijo kvantnih stanj ter druge formalne povezave med koncepti strojnega učenja in kvantne mehanike.

Algoritmi strojnega učenja pa niso uporabni le za obdelavo klasičnih podatkov, ampak tudi kvantnih. Na tem področju lahko izpostavimo dve uporabi strojnega učenja. Prva je kalibracija eksperimentov. Tukaj gre za majhne prilagoditve eksperimentalnih naprav tako, da so pravilno naravnane. Velikokrat je to zelo dolgotrajen postopek, ki ga lahko avtomatiziramo s strojnimi učenjem. Poleg kalibracije je

strojno učenje uporabno tudi pri določanju valovne funkcije ali pri kvantni tomografiji. Kvantna tomografija se ukvarja z vprašanjem, kako lahko najučinkoviteje izmerimo stanje kvantnega sistema (valovno funkcijo). Število meritev, ki jih moramo opraviti, da določimo stanje kvantnega sistema, zelo hitro narašča z njegovo velikostjo. Zato je kvantna tomografija večdelčnih kvantnih sistemov zelo težak problem, pri katerem lahko uporaba strojnega učenja bistveno zmanjša število potrebnih meritev.

Trenutno najaktivnejše področje kvantnega strojnega učenja je uporaba kvantnih računalnikov za reševanje problemov strojnega učenja. Kvantni računalnik pri tem uporabljamo kot računski pospeševalnik (podobno kot GPU ali TPU), ki implementira zaporedje kvantnih vrat z več parametri. Ti parametri se podobno kot pri standardnem strojnem učenju nevronske mreže prilagajajo glede na vhodne podatke. Poleg optimizacije parametrov kvantnih vrat sta pri tem pristopu zelo pomembna tudi kodiranje klasične informacije v kvantno stanje ter meritve. Čeprav je opisani postopek eksperimentalno zelo zahteven, so kvantne računalnike že uporabili za reševanje lažjih problemov strojnega učenja, kot je klasifikacija številk (MNIST). Čeprav so ti problemi s stališča standardnih metod strojnega učenja zelo preprosti, moramo poudariti, da se zmogljivost kvantnih algoritmov hitro večja z velikostjo kvantnih računalnikov. Ta pa v zadnjih letih močno narašča, zato je zelo težko napovedati, kdaj bodo kvantni algoritmi uspešnejši od klasičnih.

Zadnje podpodročje kvantnega strojnega učenja, obdelava kvantnih podatkov s kvantnimi algoritmi, je zaenkrat še v povojih. Sem spadajo naloge, kot sta obdelava rezultatov kvantnih eksperimentov ali pomoč pri kvantni kriptografiji. Prednost tega pristopa je neposredna manipulacija valovne funkcije brez vmesnega koraka meritve, s katerim lahko zaradi prisotnosti šuma izgubimo veliko informacije.

Predstavljena podpodročja kvantnega strojnega učenja se med seboj prepletajo in dopolnjujejo, nova dognanja pa vplivajo tudi na druga širša področja, kot so fizika, kemija in farmacija. Ravno uporabnost in splošnost kvantnega strojnega učenja sta glavni vzrok za vse večje zanimanje strokovne in širše javnosti za kvantno strojno učenje, ki se mu obeta zanimiva prihodnost.

