



Dvije sintagme iz naslova počele su dominirati (reklamnim) tekstovima popularne znanosti, medicine, kozmetike, odgoja, obrazovanja, umjetnosti, tehnologije pa čak i popularne glazbe. U ovom tekstu ukratko ćemo dati neke semantičke okvire jedne i druge sintagme i pogledati kako one postaju povezane u pristupu koji će njihovom sintezom proizvesti “kvantni skok” u modernoj inflaciji podataka i njihovog utjecaja na naš svakodnevni život. Ta sinteza ponekad nosi ime kvantna umjetna inteligencija (Quantum Artificial Intelligence) gdje paralelizam kvantnog računarstva omogućuje ubrzanje algoritama strojnog učenja, kao bitne poddiscipline umjetne inteligencije.

Pregled izlaganja:

1. Uvod
2. Kvantnomehanički principi kvantnih računala (QC)
 - ▶ Postulati kvantne mehanike
 - ▶ Kvantne tehnologije
 - ▶ Kvantno računarstvo - sadržaj
3. Umjetna inteligencija (AI) - uvod
 - ▶ Prirodna inteligencija (NI)
4. Uloga i ciljevi AI
 - ▶ Turingov test AI
 - ▶ Programski jezici AI
5. Područja primjene AI
6. Komponente AI
7. Generativna (stvaralačka) GAI
8. Kvantna generativna AI (QGAI)
 - ▶ Strah od AI ili QGAI?
9. Epilog

Kvantna mehanika je teorija mikroskopskih pojava i struktura dok nam neposredna slika tehnologije najčešće nameće slike makroskopskih objekata poput kosilica, strojeva za pranje rublja, automobila, aviona i sličnog. Postoji stalna (ponekad i spora) difuzija znanstvenih spoznaja i rezultata u praktičnu primjenu, tj. simbioza znanosti i tehnike - tehnologije. Gdje prestaje (čista) znanost, a gdje počinje tehnologija?


Kvantna teorija, iz koje izvire kvantna računala (QC) odnosno kvantno računarstvo (QC), jedna je od velikih teorija fizike koje čine konceptualnu strukturu fizike. Richard Feynman, jedan od prominentnih teoretičara kvantne teorije je 1982. godine opisao način kako bi se kvantna fizika mogla ujediniti s logikom i računarskom tehnikom i stvoriti jednu novu disciplinu koja bi ujedinila osnovne postavke kvantne teorije i osnovne tehnike računarstva [1]. Ta bi nova disciplina, možda i znanost, sadržavala niz novih mogućnosti koje bi mogle omogućiti računarski pristup prirodnim procesima ali i računarskim problemima nedostupnim klasičnim računarskim metodama.

Kvantna fizika je od njene pune fizičke i matematičke formulacije prošla dug put popločen mnogim kontroverzama i nesporazumima posebno u području njenog razumijevanja i njene interpretacije. Zato ovdje počinjemo s jednim citatom jednog od najvećih teoretskih fizičara XX stoljeća S. Weinberga, “tvorca” Standardnog modela elementarnih čestica, Nobelovog laureata (1971. godine) i autora stotine znanstvenih članaka te niza knjiga i eseja ali i stručnih knjiga iz kvantne mehanika, kvantne teorije polja i kozmologije:

“Kvantnu mehaniku smatramo danas univerzalnim matematičkim okvirom za zakone prirode. Fizičari se svi slažu s načinima primjene kvantne mehanike u računima, a oni su doista pružili zapanjujuće rezultate proračuna svojstava atoma, molekula, atomske jezgre, elementarnih čestica i još mnogo drugog. Međutim, nastavljaju se kontroverze vezane uz neka svojstva, prije svega formulacije i opravdanja njenih postulata vezanih uz mjerenja i vjerojatnost.” [2]

Kvantne tehnologije su područja preklapanja kvantne fizike i tehnologije u kojem se kvantni principi i svojstva, poput superpozicije i spletenosti primijenjuju na tehnološka područja poput računarstva, informacijske tehnologije, komunikacija, umjetne inteligencije, robotike, medicine, farmacije, pa sve do istraživanja svemira.

- ▶ 1. **Kvantno računarstvo;**
- ▶ 2. Kvantna kriptografija;
- ▶ 3. Kvantna simulacija;
- ▶ 4. Kvantna metrologija;
- ▶ 5. Kvantne informacije;
- ▶ 6. Kvantna kontrola.



Pregled povezanosti teorije informacija i QM

- ▶ (1) *Superpozicija* - Klasični proračuni (klasičnih računala) provode se bitovima koji se mogu nalaziti u samo jednom od mogućih stanja, tj. ili 0 ili 1. Qubit ili kvantni bit nalazi se u (kvantnomehantičkoj) superpoziji stanja 0 i 1, tj. qubit poprima istovremeno potencijalnu vrijednost 0 i 1.
- ▶ (2) *Kvantna interferencija* - Kvantni bitovi - qubiti - mogu interferirati kao (klasični) valovi.
- ▶ (3) *Spletenost - spregnutost* - Spregnutost je kvantni fenomen pri kojem su dvije kvantnomehantičke čestice povezane na taj način da promjene na stanju jedne čestice istovremeno dovode do promjene stanja druge čestice, bez obzira na (možda i golemu) prostornu udaljenost između čestica (teleportacija, gusto kodiranje).

- ▶ (4) *Kvantnomehaničko mjerenje* - kolaps valne funkcije u jedno od mogućih stanja koje je prije procesa mjerenja u koherentnoj superpoziciji s drugim stanjima. Taj proces se doslovno preslikava i u qubitno stanje kao superpoziciju mogućih stanja.
- ▶ (5) *Kvantna vrata* - Logičke operacije kod klasičnih računala zamijenjene su djelovanjem unitarnih operatora na qubitna stanja. Imamo, dakle, reverzibilnost kvantnih procedura.
- ▶ (6) *Kvantni paralelizam* - superpozicija qubitova omogućuje istodobnu evaluaciju više kvantnih mogućnosti.
- ▶ (7) *Kvantna dekoherencija* - glavni problem kvantnog računarstva.

- ▶ **(P1)** Svakom fizikalnom stanju kvantnomehaničkog sustava pripada *valna funkcija* koja sadrži sve podatke o stanju fizikalnog sustava odnosno u potpunosti određuje kvantni sustav. Valna funkcija pripada (beskonačno dimenzionalnom) Hilbertovom prostoru $H^{(\infty)}$ funkcija i ona je kvadratno integrabilna kompleksna funkcija svojih argumenata.
- ▶ **(P2)** Svakoj fizikalnoj veličini pridružujemo operator. Operatori fizikalnih veličina su linearni i Hermitski.
- ▶ **(P3)** Srednja ili očekivana vrijednost neke fizikalne veličine A u nekom stanju fizikalnog sustava ψ dobije se tako da se izračuna srednja vrijednost pripadnog Hermitskog operatora $\hat{A}$, tj.

$$\langle A \rangle_{\psi} = \overline{A}_{\psi} = \int \psi^* \hat{A} \psi dV$$

- **(P4)** Vremensko odvijanje fizikalnog sustava opisanog valnom funkcijom (napisanoj u jednoj dimenziji) $\psi(x, t)$ dano je rješenjem Schrödingerove jednadžbe

$$i\hbar \frac{\partial}{\partial t} \Psi(x, t) = \hat{H}(x, t) \Psi(x, t)$$

gdje je $H(x, t)$ ukupna energija - *hamiltonijan* sustava, a $\hat{H}$ je odgovarajući Hermitski operator (v. **P2**).

Klasični bitovi: 0,1

Qubit $|q\rangle$ (Diracova bra $\rightarrow \langle$ | i ket $\rightarrow |$) notacija):

$$0, 1 \rightarrow |q\rangle = \alpha|0\rangle + \beta|1\rangle = \alpha \cdot \begin{pmatrix} 1 \\ 0 \end{pmatrix} + \beta \begin{pmatrix} 0 \\ 1 \end{pmatrix} = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}$$

- superpozicija klasičnih bitova, uz normalizaciju (prema **P2**)

$$\langle q|q\rangle = (\alpha^* \ \beta^*) \begin{pmatrix} \alpha \\ \beta \end{pmatrix} = |\alpha|^2 + |\beta|^2 = 1.$$

Dvoqubitno stanje (tenzorski produkt qubitnih stanja)

$$|0\rangle \otimes |0\rangle = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \otimes \begin{pmatrix} 1 \\ 0 \end{pmatrix} = (1 \ 0 \ 0 \ 0)^\dagger \quad \text{i}$$

$$|0\rangle \otimes |1\rangle = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \otimes \begin{pmatrix} 0 \\ 1 \end{pmatrix} = (0 \ 1 \ 0 \ 0)^\dagger \quad \text{itd.}$$

Bellova stanja - Bellova baza

$$\begin{aligned} |b_{00}\rangle &= \frac{|01\rangle + |10\rangle}{\sqrt{2}} & |b_{01}\rangle &= \frac{|01\rangle - |10\rangle}{\sqrt{2}} \\ |b_{10}\rangle &= \frac{|00\rangle + |11\rangle}{\sqrt{2}} & |b_{11}\rangle &= \frac{|00\rangle - |11\rangle}{\sqrt{2}} \end{aligned}$$

- neseparabilna stanja $|\psi_{2q}\rangle \neq |\psi_1\rangle \otimes |\psi_2\rangle$. -

Peres-Horodecki kriterij za separabilnost.

- **NAND vrata** ili **NI vrata** su dvobitna vrata i predstavljaju kombinaciju NOT-AND vrata koja daju istiniti izlazni bit x samo u slučaju kada *nije* ispunjeno da su obadva ulazna bita istinita. Odgovarajući aritmetički simbol je

$$x = \overline{ab} \quad (5-59)$$

a aritmetički zapis je

$$x = 1 - a \cdot b. \quad (5-60)$$

Rabit ćemo i simbol

$$x = a \uparrow b \quad \text{ili} \quad x = \text{NAND}(a, b). \quad (5-61)$$

Valja uočiti da kružić na kraju standardnog simbola uvodi negaciju "ne".



Slika 5.5 - Simboli klasičnih NAND - NI vrata

Izlazni bit x istinit je (1) kad je bar jedan ulazni bit a i b neistinit.

Tablica 5.4

NAND $\uparrow$		
a	b	x
0	0	1
1	0	1
0	1	1
1	1	0

NAND - NI vrata

Klasična dvobitna NOT-AND vrata

- **Hadamardova vrata** - Ponekad se ta vrata zovu i Walsh-Hadamardova vrata ili Hadamardova transformacija, a definirana su ovako

$$H|0\rangle = \frac{1}{\sqrt{2}}(|0\rangle + |1\rangle) \quad \text{ i } \quad H|1\rangle = \frac{1}{\sqrt{2}}(|0\rangle - |1\rangle), \quad (5-102)$$

a u matričnom zapisu Hadamardova vrata su

$$H = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}. \quad (5-103)$$

Razmatrajući NOT vrata mi smo uveli vrata H kao unitarnu transformaciju koja je dijagonalizirala operator X . Slično kao i s Paulijevim vratima, Hadamardova vrata možemo napisati ovako

$$\begin{aligned} H &= \frac{1}{\sqrt{2}}(|0\rangle + |1\rangle)\langle 0| + \frac{1}{\sqrt{2}}(|0\rangle - |1\rangle)\langle 1| \\ &= \frac{1}{\sqrt{2}}(|0\rangle\langle 0| + |1\rangle\langle 0| + |0\rangle\langle 1| - |1\rangle\langle 1|) \\ &= \frac{1}{\sqrt{2}} \sum_{x,y=0}^1 (-1)^{xy} |x\rangle\langle y|. \end{aligned} \quad (5-104)$$

Hadamardova unitarna kvantna vrata

Stanja dobijena djelovanjem Hadamardovih vrata na stanja $|0\rangle$ i $|1\rangle$ su stanja dobijena djelovanjem unitarnog operatora na vektore baze. Premat tome, možemo očekivati da su stanja


$$\frac{|0\rangle + |1\rangle}{\sqrt{2}} = H|0\rangle \quad \text{i} \quad \frac{|0\rangle - |1\rangle}{\sqrt{2}} = H|1\rangle \quad (5-108)$$

također vektori baze, jer od ranije znamo da unitarnim transformacijama prelazimo iz (stare) baze u (novu) bazu. Doista, gornji vektori su međusobno okomiti i normirani pa smo dobili novu bazu, tzv. Hadamardovu bazu, te se uvode i oznake

$$|+\rangle = \frac{|0\rangle + |1\rangle}{\sqrt{2}} \quad \text{i} \quad |-\rangle = \frac{|0\rangle - |1\rangle}{\sqrt{2}}, \quad (5-109)$$


tj. Hadamardova baza je $\mathcal{B}_H = \{|+\rangle, |-\rangle\}$ dok našu "standardnu" bazu $\mathcal{B} = \{|0\rangle, |1\rangle\}$ zovemo računarska baza, ili kanonska baza.

Hadamardova unitarna kvantna vrata



Slika 5.15 - CNOT vrata, tj. vrata s jednim kontrolnim qubitom $|x\rangle$, koji je na gornjoj liniji gdje je puna točka. Početno dvoqubitno stanje je $|x\rangle \otimes |y\rangle = |xy\rangle$, a konačno $|x\rangle \otimes |x \oplus y\rangle = |x, x \oplus y\rangle$.


Kontrolirana NOT, tj. CNOT unitarna kvantna vrata



Slika 6.1 - Kvantna mreža s četvora Hadamardova vrata i jednim CNOT vratima i njoj ekvivalentna vrata koja djeluju na ista početna stanja.

Kvantna mreža unitarnih kvantnih vrata


D. Horvat: Kvantna računalna



Slika 6.3 - Kvantna mreža koja od dvobitnog stanja $|a\rangle \otimes |b\rangle$ generira Bellovo stanje $|b_{ij}\rangle$.


Kvantna mreža unitarnih kvantnih vrata - 2

$$\text{CNOT}|x, y\rangle = |x, x \oplus y\rangle.$$



Slika 6.4 - Kvantna mreža za generiranje Bellovih stanja
identična onoj na slici 6.3, uz raniju oznaku za CNOT vrata.


Kvantna mreža unitarnih kvantnih vrata - 3



Slika 6.18 - Mreža za teleportaciju. Qubitno stanje $|\chi\rangle$ želi se teleportirati. Gornja dva qubita ($|\chi\rangle$ i $|A\rangle$) pripadaju Alisi, odnosno, ona ih kontrolira, a donji će pripasti Bobu. Rezultate mjerenja na stanju $|\varphi_4\rangle$ Alisa će klasičnim kanalom (telefon, pismo, golub pismoša) poslati Bobu koji će uz ranije dogovorene procedure, rekonstruirati stanje $|\chi\rangle$.

Kvantna mreža za kvantnu teleportaciju

dr. sc. Branko
Hanžek[#]
prof. dr. sc.
Dubravko
Horvat^b



Prirodna inteligencija (psiholozi!) - što je to?

- ▶ (1) *Lingvistička inteligencija* povezana s vještinom govora i pisanja;
- ▶ (2) *Logičko-matematička inteligencija* opisuje vještinu baratanja brojevima;
- ▶ (3) *Glazbena inteligencija* govori o izvedbi i komponiranju glazbe;
- ▶ (4) *Prostorna inteligencija* odnosi se na sposobnost procjenjivanja i analize vidljivog svijeta;
- ▶ (5) *Tjelesno-kinetička inteligencija* govori o vještini kretanja (ples, atletika);
- ▶ (6) *Međuljudska inteligencija* opisuje vještinu razumijevanja i komunikacije s drugima;
- ▶ (7) *Osobna inteligencija* govori o vještini i sposobnosti razumijevanja samog sebe;
- ▶ (8) *Prirodna inteligencija* govori o vještini razumijevanja svijeta prirode.


Trodomna teorija inteligencije:

- ▶ (I) *Komponentna inteligencija* koja opisuje sposobnost rješavanja testova inteligencije;
- ▶ (II) *Eksperimentalna inteligencija* govori o sposobnostima prilagodbe novim situacijama i stvaranju novih ideja;
- ▶ (III) *Kontekstualna inteligencija* odgovara sposobnosti kvalitetnog funkcioniranja u svakodnevnom životu.

Ima i ovoga: “inteligentan čovjek je onaj koji posjeduje inteligenciju”.

Rječnik stranih riječi: inteligencija je sposobnost otkrivanja zakonitosti u odnosima među činjenicama i, dalje, to je ukupnost sposobnosti shvaćanja i uočavanja činjenica u neposrednom snalaženju i borbi za opstanak živih bića.

A. Turing je (prije gotovo 100 godina!) postavio pitanje: “Kako možemo znati ili zaključiti da je neki “pametni” stroj doista postigao razinu inteligencije?” On je ponudio test koji ovdje skiciramo.




Uz podatke valja razviti algoritme ML i DL učenja. Programski jezici za tu svrhu razvijali su se od LISP-a (J. McCarthy), preko PROLOGA, sve do danas možda najvažnijeg Pythona, koji posjeduje velik broj modula namijenjenih posebnim segmentima skupljanja i obrade podataka te njihovog grafičkog prikaza i prilagodbe metodama AI.

ChatGPT na upit, daje uputu za kompletnu proceduru - algoritam u Pythonu za stvaranje baze podataka iz skupa pdf-dokumenata. Pri tome se rabi jedan Pythonov modul koji obavlja selekciju rijči i hijerarhijski stvara bazu podataka koju zatim drugi modul predaje programu strojnog učenja.

Umjetna inteligencija (AI) i učenje iz podataka

KVANTNA
RAČUNALA I
UMJETNA IN-
TELIGENCIJA

dr. sc. Branko
Hanžek[#]
prof. dr. sc.
Dubravko
Horvat^b



Odnos AI, ML (machine learning - strojno učenje)
i DL (deep learning - duboko učenje).

Umjetna inteligencija (AI) i učenje iz podataka

KVANTNA
RAČUNALA I
UMJETNA IN-
TELIGENCIJA

dr. sc. Branko
Hanžek[#]
prof. dr. sc.
Dubravko
Horvat^b

Uloga AI je naučiti stroj da slijedi ono što je ranije opisano kao prirodna inteligencija.

Bitne komponente AI su, prema slici, strojno učenje ML i duboko učenje DL kao dio ML.

Duboko učenje slijedi (oponaša) prirodnu neuronsku mrežnu strukturu te pomoću višeslojne neuronske mreže kroz uzastopne slojeve uči hijerarhijske reprezentacije podataka - od osnovnih značajki u početnim slojevima do sve apstraktnijih i semantički bogatijih u dubljim slojevima.

Na taj način priređuje i omogućuje ML **učenje - treniranje** na poznatim podacima i tako naučene podatke ML rabi da ostvari novo, nenaučeno znanje.

Umjetna inteligencija (AI) i učenje iz podataka

KVANTNA
RAČUNALA I
UMJETNA IN-
TELIGENCIJA

dr. sc. Branko
Hanžek[#]
prof. dr. sc.
Dubravko
Horvat^b


Vjerodostojnost i kvaliteta odgovora na upit AI toliko je dobra koliko su dobri podatci koje je AI (DL, ML) imala, na kojima je učila i koje može rabiti,

U inflaciji podataka (po nekim podacima na You-tube se svake minute doda 500 sati video zapisa) važno je, općenito, imati neki alat koji bi u takvoj situaciji selektirao podatke.

Jedan autor opisuje situaciju i kaže: “Prije smo bili gladni podataka, a danas se utapamo u njima!”

Umjetna inteligencija (AI) i učenje iz podataka

Duboko učenje - prikaz na 3 ulazna podatka x_0, x_1, x_2 , odgovarajući broj (statističkih) težina w_{ij} , funkcija sklonosti b_n (eng. bias), aktivacijskih funkcija F, G i izlazni podatak H .



Neuronska mreža s dvije točke

Umjetna inteligencija (AI) i učenje iz podataka

Računala su ranije, prije konstrukcije GPU-a (Graphic Processing Unit) bila previše spora za treniranje DL.

Usporedba brzine: ENIAC (Electronic Numerical Integrator and Computer - 1945. g.) je oko 45.000.000 puta sporiji od računala na kojem gledamo našu prezentaciju. Računala dizajnirana posebno za DL su oko 110.000.000.000 puta brža od ENIAC-a.

Neuronske mreže za DL su organizirane u slojevima, prema slici. Svaki podatak nosi informaciju o (relativnoj) težini w_{ij} , a sklonost i aktivacijska funkcija donose dodatne podatke koje računalo mora posluživati.

Za razvoj DL pa tako i AI krucijalni je napredak u brzini računala, izum GPU, razvoj algoritama i (goleme) baze podataka.

DL procedura se može očitati sa slike: ulazni podatci x_i posjeduju relativne težine w_{ij} i te veličine se množe te se međusobno zbrajaju. Zatim ulaze kroz barijeru sklonosti b_a u aktivacijsku domenu koja proizvodi jedan izlazni podatak.

Cijeli fantastični uspjeh AI direktna je posljedica jedne takve, mogli bismo kazati, primitivne procedure. Dakle, kad se takve procedure ulančaju i slože u slojeve, rezultat je prepoznavanje slika, vožnja bez vozača, liječnička dijagnoza, prijevod Krležine poezije na francuski, nova simfonija a-la-Beethoven ili da Vincijeva “neotkrivena” slika. Jasno, za to treba imati težine w_{ij} i funkcije sklonosti (bias) b_a , a to daje trening na bazama podataka.

Umjetna inteligencija (AI) i učenje iz podataka

Prema slici, kako raste broj aktivacijskih funkcija (neuronskih čvorova odnosno ulaznih podataka) još brže raste broj relativnih težina, tako da to može predstavljati limitirajući faktor za razvoj DL a time i AI. Tu se krije veza između QC i AI!

Model kompanije OpenAI GPT-3 (prethodnik GPT-4 i ChatGPT) ima oko 175.000.000.000 relativnih težina, a vjeruje se da GPT-4 ima 1.700.000.000.000 relativnih težina.

Generativna - stvaralačka umjetna inteligencija (GAI)

KVANTNA
RAČUNALA I
UMJETNA IN-
TELIGENCIJA

dr. sc. Branko
Hanžek^a
prof. dr. sc.
Dubravko
Horvat^b

Korak dalje u razvoju AI (bio) je primjena treniranog ML (DL) na podacima koji nisu bili dio baze podataka za trening. Rezultati primjene AI na nove podatke mogu dati potpuno nova znanja te se zato takve verzije AI zovu generativne (stvaralačke) AI, tj. GAI. U GAI mnogi će uključiti ChatGPT, GitHub Copilot, GPT-4, GPT-4o, Jurassic, Bloom itd.

Na tom se mjestu susreću dva područja koja smo ovdje prikazali: QC i AI. Ako se prihvati da će jednom konstruirano komercijalno QC postići kvantnu nadmoćnost (supremacy), tada je jasno da će ono ući na velika vrata u GAI, što će dati QGAI - kvantnu generativnu umjetnu inteligenciju.

Generativna - stvaralačka umjetna inteligencija (GAI)

KVANTNA
RAČUNALA I
UMJETNA IN-
TELIGENCIJA

dr. sc. Branko
Hanžek[#]
prof. dr. sc.
Dubravko
Horvat^b

GAI je, prema autorima takvih sustava, nužno povezati s golemim bazama podataka, inteligentno organiziranti računarske algoritme, uvesti višestruki paralelizam i slijediti rezultate istraživanja ljudskog mozga.

Višestruki paralelizam pokazuje prema QC, a novi algoritmi kompatibilni s QC su već manjim dijelom razvijeni.

Godine 2013. (na poticaj američkog predsjednika B. Obame) pokrenut je projekt BRAIN (Brain Research through Advancing Innovative Neurotechnologies) čiji je cilj bolje razumijevanje funkcioniranja ljudskog mozga, što je u mnogome slično projektu ljudskog genoma.

Kvantna generativna umjetna inteligencija (QGAI)

KVANTNA
RAČUNALA I
UMJETNA IN-
TELIGENCIJA

dr. sc. Branko
Hanžek^a
prof. dr. sc.
Dubravko
Horvat^b

Ovdje valja navesti razvijene alate i platforme kvantnog strojnog učenja QML i kvantnog računarstva QC, kao pretpostavke funkcioniranja GAI i QGAI: Qiskit je IBMov alat baziran na računalnom programu Python za programiranje kvantnih računala, a Qiskit ML kao aplikacija višeg reda služi kao veza neuronskih mreža za duboko čenje, dakle, za AI; TensorFlow (Google) je alat pisan u Pythonu za strojno (dubinsko) učenje, (time i AI), točnije za treniranje neuronskih mreža, a sličan je programu PyTorch (MetaAI - Linux) koji je ML aplikacija napisana u Pythonu i namijenjena procesiranju računalnog gledanja i procesiranju prirodnih jezika. (Na tom je alatu baziran autopilot Tesla i sl.);

Kvantna generativna umjetna inteligencija (QGAI)

PennyLane je alat baziran također na Pythonu, a koji služi za povezivanje TensorFlow ili PyTorch modela s kvantnim računalnim platformama poput IBMQ ili Google Quantum. Lista slična gore skiciranima neprestano raste po obimu i po sofisticiranosti, a mi smo ovdje spomenulis samo one u ovom trenutku možda najzanimljivije.

Mogući rezultati simbioze QC i GAI u QGAI su:

- ▶ Matematičke operacije - kvantni algoritmi za vlastite vrijednosti (*eigenvalues*) - Variational Quantum Eigensolver, ...
- ▶ QC postojeći algoritmi (Shor, Glover, QFT,...) primijenjeni na AI baze podataka
- ▶ Optimizacija - QAOA (Quantum Approximate Optimization Algorithm) - QC optimizacijski algoritam za nalaženje optimuma u stohastičkom smislu. Također i adijabatski QC algoritmi (koji izlaze iz adijabatskog kvantnomehaničkog računa

Završna riječ (citat) - AI

ChatGPT je dao sljedeći odgovor kad ga je autor jedne knjige pitao: “Jesi li Ti svjesno biće?” Odgovor je bio:

Ja sam model strojnog učenja, a ne svjesno biće. Ja sam računalni program i kao takav sam treniran da generiram tekst koji je baziran na ulaznim podacima korisnika. Ja nemam sposobnost razmišljanja i zaključivanja i nemam svijest poput ljudi. Ja sam dizajniran da dajem informacije i pomažem korisniku, ali ja nemam sposobnost nezavisnog razmišljanja ili vlastite svijesti.

Kraj

KVANTNA
RAČUNALA I
UMJETNA IN-
TELIGENCIJA

dr. sc. Branko
Hanžek[#]
prof. dr. sc.
Dubravko
Horvat^b

HVALA!

Literatura i reference

- ▶ [0] M. A. Nielsen and I. L. Chuang, *Quantum Computation and Quantum Information*, Cambridge Univ. Press, Cambridge (2003)
- ▶ [1] Ch. H. Bennett, *Quantum Information and Computation*, Phys. Today, October 1995., 24;
- ▶ [2] Ph. Kaye, R. Laflamme i M. Mosca, *An Introduction to Quantum Computing*, Oxford University Press, New York (2007).
- ▶ [3] N. S. Yanofsky i M. A. Mannucci, *Quantum Computing for Computer Scientists*, Cambridge University Press, Cambridge (2008).
- ▶ [4] D. Bruss and G. Leuchs (eds), *Lectures on Quantum Information*, Wiley (2007);
- ▶ [5] M. Nakahara and T. Ohmi, *Quantum Computing - From Linear Algebra to Physical Realizations*, CRC Press (2008).
- ▶ [6] M. Pavičić, *Quantum Computation and Quantum Communication: Theory and Experiment*, Springer, New York (2007).

Literatura

- ▶ [7] M. Pavičić, *Companion to Quantum Computation and Communication*, Wiley-VCH, Weinheim (2013).
- ▶ [8] M. Le Bellac, *A Short Introduction to Quantum Information and Quantum Computation*, Cambridge Univ. Press, Cambridge (2006).
- ▶ [9] A. Yu. Kitaev, A.H. Shen, M.N. Vyalyi *Classical and Quantum Computation*, AMS, Providence (2000).
- ▶ [10] K. Warwick: *Artificial Intelligence, the basics*, Routledge, Oxon (2012).
- ▶ [11] S. Lucci, D. Kopec *Artificial Intelligence in the 21st Centuri*, 2. izd., Mercury Learning and Information, Dulles (2016).
- ▶ [12] Catherine C. McGeoch, *Adiabatic Quantum Computation and Quantum Annealing: Theory and Practice*, Sinthesis Lectures on Quantum Computing 5.2, 1-93 (2014).
- ▶ [13] N. Wiebe and L. Wossing *Generative training of quantum Boltzman machines with hidden units*, 

- ▶ [14] D. Kramer: *Will AI's Growth Create an explosion of Energy Consumption?* , Physics Today, 28-29, April 2024.;
- ▶ [15] A. Turing: *Computing Machinery and Intelligence* , Mind, 59 (236), 433-460 (1950);
- ▶ [16] D. Mišljenčević, I. Maršić: *Umjetna inteligencija*, Školska knjiga, Zagreb (1991).
- ▶ [17] D. L. Poole, A. K. Mackworth: *Python Code for Artificial Intelligence: Foundations of Computational Agents* , Independently Published (2024).
- ▶ [18] P. Joshi: *Artificial Intelligence with Python* , Packt Publishing, Birmingham (2024).
- ▶ [19] H. M. Elsherif: *Python for Artificial Intelligence: A Comprehensive Guide* , Independently Published (2024).

- ▶ [20] S. Lynch: *Python for Scientific Computation and Artificial Intelligence* , CRC Press, New York (2023).
- ▶ [21] P. Gupta, A. Bagchi: *Essentials of Python for Artificial Intelligence and Machine Learning* , Springer, New York (2023).
- ▶ [22] R. Charbonneau: *SETI, artificial intelligence, and existential projection*, Physics Today, 37-42, February 2024.