

Od kvantnega strojnega učenja do kvantne umetne inteligence: sistematični meta-pregled

From Quantum Machine Learning to Quantum Artificial Intelligence: A Systematic Meta-Review

Aleksandar Brodschneider
Univerza Alma Mater Europaea
Fakulteta ECM
Maribor, Slovenija

Matjaž Gams
Institut »Jožef Stefan«
Jamova 39
Ljubljana, Slovenija

Povzetek

Prispevek obravnava razvoj kvantnega strojnega učenja (QML) kot algoritmične, metodološke in konceptualne podlage za širši razmislek o kvantni umetni inteligenci (QAI) ter njeni možni generativni razširitvi (QGAI). Raziskava je zasnovana kot sistematični meta-pregled drugega reda po načelih PRISMA 2020. Po preverjanju bibliografske in vsebinske neodvisnosti je bilo v primerjalno analizo vključenih 17 preglednih oziroma pregledno-analitičnih virov iz obdobja 2017–2025. Sinteza kaže tri prevladujoče smeri: premik k eksperimentalnemu preverjanju na napravah NISQ, hitro širjenje hibridnih kvantno-klasičnih arhitektur ter razvoj kvantnih generativnih modelov. Rezultati ne potrjujejo QAI kot empirično uveljavljene discipline, temveč kažejo, da QML postopoma ustvarja tehnično in konceptualno osnovo za njen nadaljnji razvoj.

Ključne besede

kvantno strojno učenje, kvantna umetna inteligenca, kvantno-generativna umetna inteligenca, hibridni kvantno-klasični modeli, NISQ, sistematični meta-pregled

Abstract

This paper examines the development of quantum machine learning (QML) as an algorithmic, methodological and conceptual basis for a broader consideration of quantum artificial intelligence (QAI) and its possible generative extension (QGAI). The study applies a second-order systematic meta-review based on PRISMA 2020. After checking bibliographic and substantive independence, 17 review and review-analytical sources published between 2017 and 2025 were included. The synthesis identifies three dominant directions: a shift towards experimental validation

on NISQ devices, the rapid growth of hybrid quantum-classical architectures, and the development of quantum generative models. The results do not establish QAI as an empirically mature discipline; rather, they indicate that QML is gradually forming its technical and conceptual foundation.

Keywords

quantum machine learning, quantum artificial intelligence, quantum-generative artificial intelligence, hybrid quantum-classical models, NISQ, systematic meta-review

1 Uvod

Kvantno računalništvo se je iz pretežno teoretičnega področja razvilo v raziskovalno okolje, v katerem se preizkušajo novi algoritmi, programska ogrodja in eksperimentalne aplikacije. Na presečišču kvantne teorije informacij in strojnega učenja se je oblikovalo kvantno strojno učenje (QML), ki preučuje, ali lahko kvantni sistemi ponudijo drugačne načine kodiranja podatkov, prepoznavanja vzorcev, optimizacije in generiranja porazdelitev [1]. Njegov pomen ni omejen na možnost hitrejšega računanja. Kvantni formalizem uvaža reprezentacije, v katerih imajo osrednjo vlogo superpozicija, interferenca, prepletenost in meritev, zato odpira tudi širša vprašanja o naravi informacije in učenja.

Iz tega izhaja razlikovanje med QML in kvantno umetno inteligenco (QAI). QML je danes predvsem operativno-algoritmično področje: vključuje kvantna jedra, variacijske algoritme, parametrizirana kvantna vezja, kvantne nevronske mreže in hibridne postopke. QAI pa je širši konceptualni okvir, ki vprašanje kvantnega računanja povezuje z agentnostjo, prilagajanjem, odločanjem, reprezentacijo znanja in pomena [2, 3]. QAI zato ne nadomešča QML, temveč razširja vprašanje od uporabnosti posameznega algoritma k pogojem, pod katerimi bi kvantno podprt sistem lahko izkazoval kompleksnejše inteligentno delovanje.

Poseben raziskovalni izziv predstavlja razmerje med QML in sodobnimi generativnimi modeli. Veliki jezikovni modeli uspešno modelirajo statistične zakonitosti jezika, vendar njihove zmogljivosti same po sebi niso dokaz semantičnega

razumevanja. Kvantni generativni modeli, zlasti kvantne generativne nasprotniške mreže (QGAN), pa raziskujejo učenje in vzorčenje kompleksnih verjetnostnih porazdelitev [7, 8]. Možno povezovanje teh smeri je v raziskavi poimenovano kvantno-generativna umetna inteligenca (QGAI), vendar izključno kot razvojna hipoteza, ne kot že vzpostavljena disciplina.

Namen prispevka je povzeti sistematično analizo pregledne literature in odgovoriti na tri vprašanja: v kolikšni meri raziskave QML že vključujejo koncepte QAI; kateri metodološki pristopi prevladujejo pri empiričnem preverjanju QML in kako zanesljivi so; ter ali lahko povezava QML z velikimi jezikovnimi modeli utemelji prihodnji razvoj QGAI. Osrednja teza je previdna: QML je najtrdnjša empirična in algoritmična osnova za razpravo o kvantno podprti inteligenci, vendar sedanji dokazi še ne omogočajo sklepa, da je QAI tehnološko ali empirično uveljavljena.

2 Teoretično izhodišče

Kubit je lahko predstavljen kot superpozicija osnovnih stanj, večkubitni sistemi pa lahko tvorijo prepletena stanja, katerih korelacij ni mogoče učinkovito opisati z enostavnimi klasičnimi modeli. Toda sama superpozicija še ne zagotavlja kvantne prednosti. Uporaben rezultat nastane šele, ko algoritem z nadzorovanimi transformacijami in interferenco okrepi amplitude želenih izidov, meritev pa iz kvantnega stanja pridobi klasično informacijo. Za QML je zato odločilna celotna veriga: priprava in kodiranje podatkov, struktura vezja, optimizacija parametrov, število meritev ter primerjava z ustreznimi klasičnimi modeli.

Najpogostejše obravnavani modeli sodobnega QML so variacijski kvantni algoritmi (VQA), kvantne nevronske mreže (QNN), kvantne jedrne metode in hibridne kvantno-klasične arhitekture [4–6]. Variacijski pristop uporablja parametrizirano kvantno vezje za izračun stroškovne funkcije ali pričakovanih vrednosti, klasični optimizator pa na podlagi meritev posodablja parametre. Takšna delitev je primerna za naprave NISQ, ki so omejene s šumom, dekoherenco, številom kubitov, globino vezij in napakami meritev. Hibridnost zato ni zgolj začasni kompromis, temveč praktični računski model, v katerem kvantni procesor prevzema specializirane naloge, klasični del pa nadzor, predobdelavo, optimizacijo in interpretacijo [5].


Prehod od QML k QAI je predvsem konceptualen. V operativnem pomenu se QAI nanaša na kvantno podprte modele učenja, odločanja in prilagajanja. V širšem pomenu pa odpira vprašanje, ali lahko kvantni formalizmi prispevajo k drugačni reprezentaciji konteksta, negotovosti in pomena. Raziskava pri tem ne enači kvantnega procesiranja z zavestjo ali človeškim razumevanjem. QAI obravnava kot teoretični okvir, ki izhaja iz preverljivih dosežkov QML in omogoča znanstveno razpravo o prihodnjih kvantno podprtih agentih in generativnih sistemih.

3 Metodologija

Raziskava je zasnovana kot sistematični meta-pregled drugega reda oziroma »umbrella review«, namenjen

kvalitativni primerjalni sintezi pregledne literature, ne statističnemu združevanju primarnih eksperimentov. Postopek identifikacije, presejanja in vključitve virov je sledil izhodiščem PRISMA 2020 [9]. Iskanje je bilo izvedeno 9. oktobra 2025 v bazah Scopus, Web of Science in SpringerLink za obdobje 2013–2025. Osnovni iskalni niz je bil ("quantum machine learning" OR "quantum artificial intelligence") AND ("review" OR "survey" OR "overview") in je bil sintaktično prilagojen posameznim iskalnim vmesnikom, vsebinsko pa je ostal enak. Kjer je bilo mogoče, so bili uporabljeni časovni, področni in dokumentni filtri. Vključeni so bili recenzirani pregledni oziroma pregledno-analitični viri, ki obravnavajo QML, QAI ali hibridne kvantno-klasične pristope, so bili objavljeni v obdobju 2013–2025 in imajo razviden metodološki opis namena, obsega ter načina izbire, razvrščanja ali sinteze literature. Ker v letih 2013–2016 ni bilo najdenih virov, ki bi izpolnjevali vsa merila, končni vzorec zajema obdobje 2017–2025.

Identificiranih je bilo 353 zapisov; po odstranitvi 39 dvojnikov je ostalo 314 zapisov. Po presejanju naslovov in izvlečkov je bilo izločenih 238 zapisov, 76 pa jih je prešlo v pregled polnega besedila. V tej fazi je bilo izločenih 56 prispevkov, ki niso izpolnjevali enega ali več meril glede vrste publikacije, tematske relevantnosti, recenziranosti, časovnega okvira ali razvidnosti metodološkega opisa. Od 20 upravičenih zapisov so bili trije zaradi vsebinskega prekrivanja izločeni, da bi preprečili dvojni štetje in nesorazmerno ponderiranje iste raziskovalne linije; ohranjeni so bili obsežnejši in novejši viri. Končni vzorec je tako obsegal 17 analitično neodvisnih enot.



Slika 1: Postopek izbire virov po načelih PRISMA 2020.

Podatki so bili ekstrahirani v standardizirano Excelovo matriko (avtorji, leto, tema, metodologija, ključni prispevek). Tematsko kodiranje je temeljilo na šestih vnaprej določenih


kategorijah: kvantni algoritmi; hibridni kvantno-klasični pristopi; teoretični modeli QAI; aplikativne domene QML; semantični in generativni elementi v povezavi z LLM in QGAI; ter konceptualni prehod QML–QAI–QGAI. Analiza je potekala v treh fazah: tematsko kodiranje, primerjalna sinteza in konceptualno mapiranje. Tematsko kodiranje in primarno analizo je izvedel prvi avtor, kodni in analitični okvir ter interpretacijo rezultatov pa sta v okviru strokovnega pregleda validirala mentor in somentor raziskave. Neodvisno dvojno kodiranje celotnega vzorca in formalni izračun medkoderske zanesljivosti nista bila izvedena. Pri interpretaciji je bila kvalitativno upoštevana tudi metodološka preglednost pregledov: jasnost namena in obsega, preglednost izbire in analize virov, obravnava omejitev ter sledljivost med ugotovitvami in sklepi. To ni predstavljalo formalnega numeričnega ocenjevanja kakovosti. Ker vključeni pregledi sami sintetizirajo širše sklope primarnih raziskav, 17 virov predstavlja analitične enote drugega reda; ugotovljeni trendi zato opisujejo vzorce v analizirani pregledni literaturi in ne statistično reprezentativne ocene celotnega področja QML/QAI.

4 Rezultati

Analiza je pokazala tri prevladujoče razvojne smeri. Prva je premik od teoretičnih in algoritmičnih zasnov k eksperimentalno preverljivim modelom na napravah NISQ. Zgodnja literatura je poudarjala predvsem potencial kvantne linearne algebre, optimizacije, kvantnih podpornih vektorjev in Boltzmannovih strojev [1]. Novejši pregledi pa vse pogosteje obravnavajo parametrizirana vezja, VQA, QNN, kvantne jedrne metode in izvedbe na dejanski ali šumno simulirani strojni opre [4, 10–14]. Ta premik potrjuje rast eksperimentalne dejavnosti, ne pa še splošne kvantne prednosti.

Druga smer je naraščajoča integracija kvantnih in klasičnih metod. V tipičnem hibridnem sistemu klasična komponenta pripravi podatke, vodi optimizacijo, primerja rezultate in skrbi za interpretacijo, kvantna komponenta pa izvede preslikavo značilk, izračun jedra, variacijsko transformacijo ali generativno vzorčenje. Takšne arhitekture so trenutno najperspektivnejša pot med omejitvami naprav NISQ in prihodnjimi zmogljivejšimi kvantnimi sistemi. Trend se širi tudi v kvantno federirano učenje, kjer se hibridni modeli povezujejo s porazdeljenim učenjem, lokalno obdelavo in varnostnimi mehanizmi [15].

Tretja smer je postopna konceptualna razširitev QML proti QAI in QGAI. V novejših virih so opaznejše teme adaptivnosti, kvantnih učnih agentov, kontekstualnosti in generativnega modeliranja. Najbolj konkretno empirično jedro te razširitve predstavljajo QGAN in drugi kvantni generativni modeli [7, 8]. Vendar tematska prisotnost QAI ali QGAI ne pomeni enake stopnje empirične zrelosti. Graf na sliki 2 je kvalitativna sintezna ocena analiziranih virov, ne bibliometrična meritev ali statistična napoved.



Slika 2: Kvalitativna sinteza tematske prisotnosti QML, QAI in QGAI v izbranih virih.

Odgovor na prvo raziskovalno vprašanje je, da QML že vključuje posamezne elemente, značilne za QAI: adaptivno učenje, kvantne agente, hibridno odločanje, semantično modeliranje in generativne pristope. Ti elementi pa še ne tvorijo enotnega, empirično potrjenega modela QAI. QML je zato mogoče razumeti kot metodološko in tehnično podlago, iz katere se lahko razvija širši koncept kvantne inteligence. Odgovor na drugo raziskovalno vprašanje izpostavlja VQA, QNN, kvantne jedrne metode in hibridne modele kot najpogostejše pristope k validaciji. Njihova znanstvena zanesljivost je omejena z dekoherenco, šumom, majhnim številom kubitov, nestabilnostjo gradientov, stroški meritev, različnim kodiranjem podatkov ter pomanjkanjem standardiziranih podatkovnih množic in primerjalnih protokolov. Primerjave klasičnih in kvantnih modelov pogosto potrjujejo izvedljivost, ne pa dosledne prednosti kvantnega pristopa [10, 11].

Odgovor na tretje raziskovalno vprašanje je najbolj zadržan. Analizirani korpus ne vsebuje neposredno empirično potrjene integracije QML in velikih jezikovnih modelov. Povezava je za zdaj konceptualna: kvantni podsistem bi lahko izvajal generativno vzorčenje, preslikavo značilk ali optimizacijo, klasični jezikovni podsistem pa obdelavo jezika in interakcijo; integracijski sloj bi povezoval reprezentacije, nadzor in povratne informacije. Tak trislojni okvir je raziskovalna hipoteza, ki zahteva prototipe in eksperimentalno preverjanje.

5 Razprava

Osrednja ugotovitev je, da je treba strogo razlikovati med tehnično izvedljivostjo, merljivo kvantno prednostjo in širšimi trditvami o inteligenci. Uspešna izvedba majhnega QML-modela na kvantnem procesorju dokazuje, da je mogoče določeno arhitekturo implementirati, ne dokazuje pa, da model pri realističnih podatkih prekaša najboljši klasični pristop. Še manj dokazuje agentnost, razumevanje ali zavest. Ta razmejitev je bistvena za preprečevanje prenatrženih sklepov v hitro razvijajočem se področju. Razvojni lok je mogoče povzeti v treh ravneh. QML je empirična in algoritmična raven, na kateri se razvijajo in primerjajo modeli učenja, optimizacije ter reprezentacije podatkov. QAI je teoretični razširitveni okvir, ki preučuje, kako bi kvantni principi lahko vplivali na agentnost, kontekstualno odločanje in reprezentacijo pomena. QGAI pa je nastajajoča generativna smer, ki povezuje kvantno učenje,

generativno modeliranje in možno semantično reprezentacijo. Ravni so povezane, vendar niso enako zrele: največ empiričnih dokazov ima QML, najmanj pa QGAI.

Raziskava ima več omejitev. Temelji na sekundarnih podatkih in ne vključuje neposrednega preizkušanja algoritmov na realnih kvantnih procesorjih; rezultati so zato odvisni od kakovosti, obsega in metodološke doslednosti obstoječih pregledov. Tematsko kodiranje ni bilo neodvisno podvojeno z drugim koderjem, zato formalna medkoderska zanesljivost ni bila izračunana; interpretativna narava kodiranja, zlasti pri povezavah QML–QAI–QGAI, predstavlja dodatno omejitev. Terminologija QAI, kvantnega agenta, kvantne semantike in QGAI še ni standardizirana, vključevanje velikih jezikovnih modelov pa ostaja konceptualno in ne predstavlja dokaza semantičnega razumevanja.

Prihodnje delo bi moralo dati prednost preverljivim prototipom hibridnih in kvantno-generativnih modelov, transparentnim klasičnim izhodiščem ter ponovljivim eksperimentalnim protokolom. Potrebni so enotnejša terminologija, standardizirane podatkovne množice in metrike, jasnejše poročanje o stroških kodiranja in meritev ter boljša ocena vpliva šuma. Pomembna so tudi vprašanja razločljivosti, nadzora, varnosti, zasebnosti in odgovornosti, zlasti pri porazdeljenih in federiranih kvantno-klasičnih sistemih.

6 Zaključek

Kvalitativna sinteza 17 analitično neodvisnih preglednih virov kaže, da se v analizirani literaturi iz obdobja 2017–2025 QML vse izraziteje usmerja od pretežno teoretičnih zasnov k eksperimentalnim, hibridnim in generativnim pristopom. Hibridne kvantno-klasične arhitekture omogočajo preizkušanje kvantnih komponent v pogojih NISQ, kvantni generativni modeli pa širijo raziskovalni prostor proti QGAI; povezava z velikimi jezikovnimi modeli za zdaj ni empirično potrjena.

Sklep raziskave zato ni, da kvantna umetna inteligenca že obstaja kot samostojna disciplina, temveč da QML oblikuje pogoje za njeno znanstveno obravnavo. QML zagotavlja tehnično in empirično osnovo, QAI konceptualno razširitev, QGAI pa možno generativno nadgradnjo. Nadaljnji napredek bo odvisen ne le od zmogljivejše strojne opreme, temveč tudi od kakovosti eksperimentov, standardizacije, razločljivosti in jasnega razlikovanja med dokazano zmogljivostjo ter konceptualnimi možnostmi.

References / Literatura

- [1] Biamonte, J. et al. (2017). Quantum machine learning. *Nature*, 549(7671), 195–202. DOI: 10.1038/nature23474.
- [2] Dunjko, V. and Briegel, H. J. (2018). Machine learning & artificial intelligence in the quantum domain: A review of recent progress. *Reports on Progress in Physics*, 81(7), 074001. DOI: 10.1088/1361-6633/aab406.
- [3] Wichert, A. (2014). *Principles of Quantum Artificial Intelligence*. Singapore: World Scientific. DOI: 10.1142/8980.
- [4] Cerezo, M. et al. (2021). Variational quantum algorithms. *Nature Reviews Physics*, 3(9), 625–644. DOI: 10.1038/s42254-021-00348-9.
- [5] Callison, A. and Chancellor, N. (2022). Hybrid quantum-classical algorithms in the noisy intermediate-scale quantum era and beyond.

- Physical Review A*, 106(1), 010101. DOI: 10.1103/PhysRevA.106.010101.
- [6] Benedetti, M. et al. (2019). Parameterized quantum circuits as machine learning models. *Quantum Science and Technology*, 4(4), 043001. DOI: 10.1088/2058-9565/ab4eb5.
- [7] Lloyd, S. and Weedbrook, C. (2018). Quantum generative adversarial learning. *Physical Review Letters*, 121(4), 040502. DOI: 10.1103/PhysRevLett.121.040502.
- [8] Ngo, T. A., Nguyen, T. and Thang, T. C. (2023). A survey of recent advances in quantum generative adversarial networks. *Electronics*, 12(4), 856. DOI: 10.3390/electronics12040856.
- [9] Page, M. J. et al. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. DOI: 10.1136/bmj.n71.
- [10] Tychola, K. A., Kalampokas, T. and Papakostas, G. A. (2023). Quantum machine learning—An overview. *Electronics*, 12(11), 2379. DOI: 10.3390/electronics12112379.
- [11] Guju, Y., Matsuo, A. and Raymond, R. (2024). Quantum machine learning on near-term quantum devices: Current state of supervised and unsupervised techniques for real-world applications. *Physical Review Applied*, 21(6), 067001. DOI: 10.1103/PhysRevApplied.21.067001.
- [12] Chen, L. et al. (2024). Design and analysis of quantum machine learning: A survey. *Connection Science*, 36(1), 2312121. DOI: 10.1080/09540091.2024.2312121.
- [13] Peral-García, D., Cruz-Benito, J. and García-Peñalvo, F. J. (2024). Systematic literature review: Quantum machine learning and its applications. *Computer Science Review*, 51, 100619. DOI: 10.1016/j.cosrev.2024.100619.
- [14] Rodríguez-Díaz, F. et al. (2025). A survey of quantum machine learning: Foundations, algorithms, frameworks, data and applications. *ACM Computing Surveys*, 58(4), Article 91, 1–35. DOI: 10.1145/3764582.
- [15] Ballester, R., Cerquides, J. and Artiles, L. (2025). Quantum federated learning: A comprehensive literature review of foundations, challenges, and future directions. *Quantum Machine Intelligence*, 7, 73. DOI: 10.1007/s42484-025-00292-2.