

Kvantne generativne suparničke mreže za generisanje naučnih rezultata

Vladimir Arsoški

Apstrakt—Već dugi niz godina smo svedoci da je veliki broj publikacija efikasno sredstvo za priznavanje izuzetne kompetentnosti i talenta u nauci, što može omogućiti pojedincu veliku moralnu i finansijsku satisfakciju. Čuvena fraza u akademskim krugovima “objavi ili nestani” postaje surova realnost. U želji da objave senzacionalna otkrića, pojedinci pokušavaju da lažiraju naučne rezultate, kako bi stvorili privid izuzetnosti. Savremeni programi za analizu slika, zasnovani na veštačkoj inteligenciji, su se pokazali kao efikasno sredstvo za razotkrivanje lažiranih prikaza naučnih rezultata i doveli su do povlačenja velikog broja sumljivih publikacija iz časopisa u poslednjih nekoliko godina. Novi algoritmi veštačke inteligencije zasnovani na generativnim suparničkim mrežama pružaju mogućnost za generisanje slika koje mogu biti klasifikovane kao verodostojne. Implementacija ovih algoritama na kvantnim računarima se pokazala kao potencijalno superioran metod generacije slika, te predstavlja realnu opasnost da slučajevi lažiranja naučnih rezultata ostanu neprimećeni. Ovo nameće potrebu da se u bliskoj budućnosti razvije disciplina koja bi se mogla opisati kao forenzika naučnih rezultata i koja bi se bavila razotkrivanjem primena ne samo klasičnih, već i kvantnih algoritima za generisanje rezultata.

Ključne reči — generativne suparničke mreže; veštačka inteligencija; kvantni računari.

I. UVOD

Proces publikovanja naučnih radova u časopisima je započeo sredinom 17. veka kada je na inicijativu Henry Oldenburg-a, prvog sekretara Kraljevskog društva, pokrenut prvi naučni časopis *Philosophical Transactions of Royal Society* [1]. Pre toga su naučnici razmenjivali ideje i rezultate na naučnim skupovima i putem privatnih korespondencija, što je ograničavalo pristup najnovijim saznanjima široj populaciji. Koncept publikovanja radova u časopisima zasnovao se na ideji diseminacije i verifikacije novih ideja, saznanja i rezultata u cilju progresa nauke. Vremenom je razvijena metodologija bavljenja naučnim radom, koja je standardizovala i formalizovala istraživačke metode, kao i način prezentacije naučnih radova i zacrtala osnovna moralna načela, koja su vezana za akademski integritet i čestitost.

Od početka devetnaestog veka, mnogi poznati univerziteti u Evropi su počeli da pridaju podjednak značaj podučavanju i naučnom radu [1]. U poslednje vreme, rasprostranjeno je mišljenje da naučni rad ima mnogo veći značaj od nastavnog

rada. Mnogi univerziteti vrše selekciju kandidata na osnovu broja publikacija, što može da usmeri nastavnike i saradnike da se intenzivno bave naučnim radom zapostavljajući nastavne delatnosti i mentorski rad. Neretko se dešava da nastavnici organizuju intenzivne prezentacije svojih naučnih dostignuća, čak i na predavanjima, kako bi privukli što veći broj potencijalnih kandidata za bavljenje naučnim radom u nadi da će povećati produktivnost publikovanja. Pritom, zbog sopstvenog angažovanja u nastavi i naučnom radu, često nemaju vremena da se dovoljno posvete mentorskom radu. Dešava se da mladi istraživači iz neznanja produkuju nedovoljno kvalitetne radove, sa pogrešnim ili modifikovanim rezultatima i bez citiranja korišćenih referenci.

Povećanje produkcije radova na godišnjem nivou dovodi do porasta broja naučnih časopisa [2]. U poslednja tri veka, rast broja aktivnih naučnih časopisa godišnje u procentima je približno konstantan i varira oko srednje vrednosti 3.46 %, što odgovara udvostručenju broja časopisa na svakih 20 godina [3]. Poslednjih godina, ovaj trend se povećava, te smo svedoci skoro svakodnevne pojave raznih časopisa čiji je naziv povezan sa oblašću, koja je u žiži naučnog interesovanja. Većina časopisa proverava originalnost, kvalitet prezentacije i značaj razmatrane problematike, tako što vrši selekciju radova pomoću ocenjivanja od strane dva ili više stručnjaka iz oblasti rada (engl. peer-reviewed). Iako se naučna zajednica i broj znanaca u većini oblasti rapidno povećava, postavlja se pitanje njihove raspoloživosti za recenziju rada, što je često vezano za veliko angažovanje samog recenzenta na produkciji radova. Velikom broju naučnih radnika se dešavalо da rad bude predložen za publikaciju ili bude odbijen bez detaljnijeg i konkretnog objašnjenja od strane recenzenta.

Sve veća ulaganja u istraživanja i nauku, kao i velika konkurenca istraživačkih grupa, dovele je poslednjih godina do pojave slučajeva tendencioznih prevara pri akviziciji i prezentovanju naučnih rezultata. U praksi su postale standardne prevare poput *plagiarizma* (prisvajanje tuđih naučnih rezultata), *autoplagiarizma* (objavljivanje istih rezultata u više naučnih časopisa), “*seckanja salame*” (prezentacija jednog naučnog dostignuća kroz seriju radova pod izgovorom obimnosti problematike), “*autora duhova*” (dodavanje na rad autora koji nisu dali značajan doprinos radu) i raznih drugih neetičkih radnji [4].

Statistika je pokazala da samo oko 45 % radova objavljenih u vrhunskim naučnim časopisima iz oblasti biomedicine imaju citate u prvih 5 godina, a od tog broja 5-25% su autocitati i ili kocitati [4]. Posebno neetički aspekt prevara odnosi se na časopise iz ove oblasti, gde dolazi do obmanjivanja naučno-stručne javnosti, a posredno i pacijenata, o mogućem brzom i

Vladimir Arsoški – Elektrotehnički fakultet, Univerzitet u Beogradu, Bulevar kralja Aleksandra 73, 11020 Beograd, Srbija (e-mail: vladimir.arsoski@etf.bg.ac.rs).

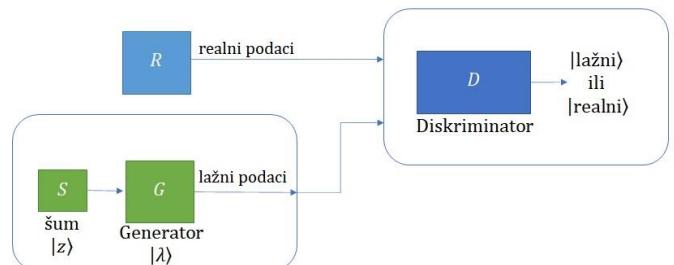
efikasnom izlečenju. Falsifikovanje naučnih rezultata obično je vezano za mikroskopski prikaz slike biomaterijala, ćelija i tkiva [5] ili za grafički prikaz "rezultata merenja" [6]. Neki od ovih radova su dostupni u bazi matičnog časopisa [5], dok na drugima stoji oznaka da su povučeni [6]. Ovi [5,6] i slični slučajevi "dorade" naučnih rezultata, otkriveni su primenom savremenih metoda i programa za analizu slike zasnovanih na veštačkoj inteligenciji. Neka softverska rešenja su besplatno dostupna na internetu, poput *Forensically* [7]. Postoje organizacije koje prate i javno objavljaju podatke o povučenim radovima [8] jer se često dešava da časopisi, zbog čuvanja reputacije, netransparentno uklone rad iz svoje baze podataka. Prema podacima sa sajta [8], do trenutka pisanja ovog rada, povučeno je čak 219 naučnih radova vezanih za COVID-19 pandemiju.

Dosada otkrivene prevare, vezane za objavljivanje lažiranih naučnih rezultata, uglavnom su se zasnivale na korišćenju softvera za odbradu slike, gde su nedoslednosti u vidu kloniranja delova slike, nepravilnog gradijenta boje, osvetljenja, šuma i defekata na slici, mogli da budu detektovani pomoću metoda zasnovanih na mašinskom učenju [7]. U skorije vreme su se pojavili generativni modeli mašinskog učenja, poput varijacionog autoenkodera (VAE) koji predstavlja veštačku neuralnu mrežu koja pripada familiji probabilističkih grafičkih modela [9]. Ovaj model formulise problem statističkog zaključivanja (na osnovu slučajne veličine zaključak je druga slučajna veličina), kao statistički problem optimizacije. VAE je usmeren model, trening (obučavanje) se može obaviti primenom modela zasnovanih na gradijentu i lako se može generalizovati za rešavanje raznih problema [10]. VAE model, vezan za generisanje slika, uspešno je implementiran u programskom paketu *Keras* pod programskim jezikom *Python*. Nedostatak VAE ogleda se u inherentnoj osobini, koja leži u samoj postavci modela, da produkuje relativno "zamućen" izlaz (engl. blur), kada je reč o treniranju za generaciju slika [10], što softver za forenziku može označiti kao mogući problem.

Potencijalno superioran model generativne mreže je generativna suparnička mreža (engl. Generative Adversarial Network - GAN), koja se zasniva na teorijskom scenariju takmičenja između mreže koja generiše uzorce (*generatora*) i mreže *diskriminatora*, koja pokušava da napravi razliku između realnih podataka iz skupa za trening i generisanih podataka [11]. Najbolje performanse modela se postižu za scenario u kojem generator pokušava da poveća vrednost logaritma verovatnoće da diskriminator pogreši, umesto da smanjuje vrednost logaritma verovatnoće da diskriminator dà tačan odgovor [10,11]. Kada se trening završi, diskriminator sa podjednakom verovatnoćom klasificuje generisane slike kao prave ili pogrešne i može da se apstrahuje. Na ovaj način, generator je naučen da prevari sistem veštačke inteligencije. Demonstrirano je da duboke konvolucione GAN mogu da generišu izuzetno verodostojne slike [12], što ih čini potencijalno opasnim za generisanje slika u naučnim publikacijama koje može da prođe nezapaženo.

Razvoj kvantnih računara obećava veliki napredak u oblasti hemije, biomedicine, rešavanja kompleksnih matematičkih i

fizičkih problema, kao i implementacije naprednih sistema veštačke inteligencije. Efekti inherentni za kvantu mehaniku, poput superpozicije, interferencije i kvantne zapletenosti (engl. entanglement), mogu dovesti do veće efikasnosti kvantnih algoritama u odnosu na klasične [13]. Za razliku od kvantnog sistema, koji je po prirodi probabilistički, klasični sistemi ne mogu efikasno generisati slučajne veličine (već se govori o pseudo-slučajnim veličinama). Zbog toga su kvantni sistemi, koji su vezani za stohastičke algoritme, značajno jednostavniji i ujedno efikasniji od klasičnih probabilističkih. Takođe je poznato da je za predstavljanje vektora u N -dimenzionom prostoru potrebno $\log_2 N$ kubita, kao i da je vreme manipulacije kvantnog sistema nad retkim matricama složenosti u vremenu reda $O(\text{poly}(\log_2 N))$ [13]. Sve ovo dovodi do potencijalne prednosti kvantnih u odnosu na klasične algoritme, pogotovu kada je reč o visokodimenzionim prostorima i stohastičkim procesima. Uprkos činjenici da je kvantni hardver u svom ranom povoju i da su trenutne implementacije podložne dekoherenciji, spoljašnjem šumu i imaju ograničene mogućnosti povezivanja kubita, postoje indikacije da će kvantno mašinsko učenje biti jedna od prvih značajnih primena na kvantnom hardveru. Veliki broj algoritama mašinskog učenja je već adaptiran za rad na kvantnom računaru [14], a od skora i GAN pod nazivima QGAN i QuGAN [15,16]. QGAN je, između ostalog, našao primene vezane za generisanje realističnih raspodela [17,18] i slika [19], gde je demonstrirao jednostavniju implementaciju i eksponencijalno ubrzanje u odnosu na klasičnu GAN.



Sl. 1. Šematski prikaz kvantne generativne suparničke mreže. Ulazni podaci za diskriminator D su kvantna stanja iz generatora G (čiji ulaz pobuduje stohastički vektor $|z\rangle$) ili iz realnog izvora podataka R . Izlaz diskriminatora je kvantno stanje $|\text{lažni}\rangle$ ili $|\text{realni}\rangle$ i odnosi se na procenu porekla ulaznog podataka. Slika je adaptirana na osnovu rada [15].

II. MODEL KVANTNE GENERATIVNE SUPARNIČKE MREŽE

Šematski prikaz kvantne generativne suparničke mreže je dat na Sl. 1. R predstavlja izvor realnih podataka koji za zadatu kvantu labelu $|\lambda\rangle$ generiše realne podatke. Svrha QGAN-a je da definise generator G koji imitira izvor realnih podataka R . G predstavlja varijaciono kvantno kolo, čiji su gejtovi parametrizovani vektorom Θ_G . Na osnovu stanja $|\lambda\rangle$ i dodatnog stohastičkog stanja $|z\rangle$ generator produkuje stanje na svom izlazu koje treba da bude slično stanju koje daje R . U

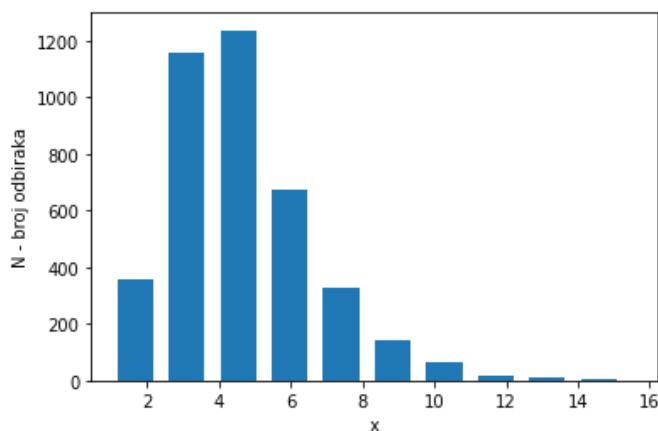
opštem slučaju, dodatno stanje $|z\rangle$ je stohastičko i ponaša se kao nestruktuirani šum koji dovodi do porasta entropije raspodele generisanih podataka, te se za jednu istu labelu $|\lambda\rangle$, može generisati više izlaznih stanja. Podaci za obučavanje generatora se dobijaju od diskriminatora koji predstavlja kvantno kolo parametrizovano vektorom θ_D . Uloga diskriminatora je da proceni da li ulazno stanje potiče od realnog izvora ili generatora, dok je uloga generatora da "prevari" diskriminator, tako da podatke koji su generisani označi kao realne. Cilj optimizacije QGAN obučavanja je da se definišu parametri diskriminatora koji će da maksimizuju verovatnoću da je diskriminator pravilno označio ulazni vektor, a ujedno i parametri generatora koji minimizuju ovu verovatnoću. Za nominalno prebrojivu vrednost Λ , labela $|\lambda\rangle$, ovaj problem se formalno definiše izrazom [15]:

$$\min_{\theta_G} \max_{\theta_D} \frac{1}{\Lambda} \sum_{\lambda=1}^{\Lambda} P\{[(D(\theta_D, |\lambda\rangle), R(|\lambda\rangle)) = |\text{realni}\rangle] \cap [(D(\theta_D, |\lambda\rangle), G(\theta_G, |\lambda, z\rangle)) = |\text{lažni}\rangle]\}. \quad (1)$$

U iterativnom postupku se određuju parametri kvantnih kola, tako da generator može što uspešnije da prevari diskriminator [15].

III. REZULTATI I DISKUSIJA

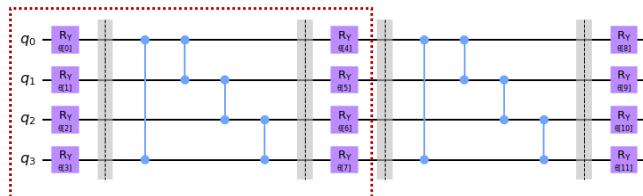
Za implementaciju modela je korišćena biblioteka *Qiskit* [20], koja radi pod programskim jezikom *Python* u virtuelnom okruženju *Anaconda*. Realizovana je QGAN za generisanje log-normalne raspodele, koja se može sresti u biomedicinskim primenama. Primer jedne realne raspodele je dat na Sl. 2. Realizacija QGAN-a na samo 2 kubita pomoću jednostavne kvantne mreže korišćene za realizaciju kvantnog generatora postoji kao primer u tutorijalima *Qiskit*-a [21].



Sl. 2. Prikaz histograma za jedan vektor realnih podataka. Za korišćeni sintetički skup od 4000 ulaznih podataka je fitovanjem dobijeno da podleže log-normalnoj raspodeli sa srednjom vrednošću $\mu=1.5$ i standardnim odstupanjem $\sigma=0.4$.

A. Pretpostavka kvantnog kola

Za realizaciju osnovnog sloja kvantnog kola generatora je usvojena *pretpostavka* (engl/nem. *ansatz*) definisana na 4 kubita. Ponavljanjem ovog bloka se postiže veća efikasnost obavljanja zadatka od strane kvantnog kola, ali se produžava vreme obučavanja usled povećanja dubine kvantne mreže. Svaki blok se sastoji od parametrizovanih jednokubitnih R_Y operacija primenjenih na svaki kubit i dvokubitnih C_Z operacija, kojima se ostvaruje međusobno *kvantno sprezanje* (engl. *quantum entanglement*) svih susednih stanja kubita. Poslednji kubit je dodatno spregnut sa prvim kubitom. Ovakvo povezivanje je vezano za pojам kružnog umrežavanja. Za implementaciju kvantne mreže je korišćena ugrađena biblioteka *TwoLocal*, gde je atribut željenog sprezanja *entanglement* = "circular", dok je parameter ponavljanja *rep* uzimao vrednosti 1 ili 2. U ovakvoj konfiguraciji, kvantna mreža ima samo 8 i 12 varijabilnih parametara, za mrežu formiranu od jednog i dva osnovna bloka, redom. Varijabilni parametri se podešavaju pri obučavanju mreže. Šema pretpostavke kola generatora je data na Sl. 3.



Sl. 3. Šema pretpostavke (engl/nem. *ansatz*) kvantnog kola generatora. Osnovni blok/sloj je uokviren crvenom isprekidanom linijom.

Diskriminator je implementiran pozivanjem funkcije *NumpyDiscriminator* i predstavlja klasičnu neuralnu mrežu sa 3 *слоја* (engl. *layer*), koja koristi *Leaky ReLU* aktivaciju u *скривеном слоју* (engl. *hidden layer*) i aktivaciju *sigmoid* funkcijom u izlaznom sloju. Na ovaj način ćemo ustanoviti uslove, pri kojima bi kvantni generator "prevario" klasični diskriminator, koji je zadužen za testiranje prezentovanih rezultata. Za optimizaciju varijabilnih parametra generatora i diskriminatora je korišćen predefinisani *Adam* algoritam [22], koji predstavlja metodu za stohastičku optimizaciju.

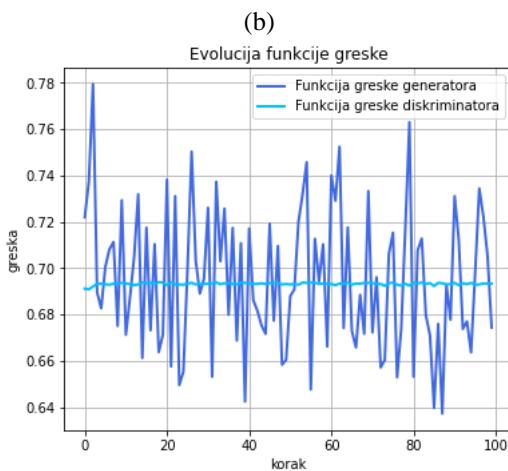
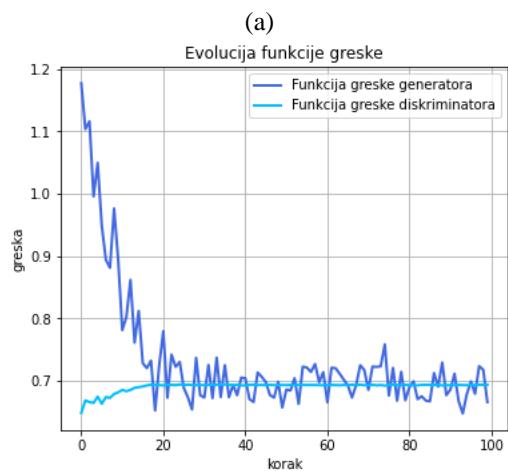
B. Obučavanje mreže

Obučavanje je najpre testirano na simulatoru raspoloživom u programskom paketu *Qiskit*. Trening mreže je obavljen korišćenjem 100 *uzoraka u svakoj iteraciji* (engl. *batch size*). Najpre je korišćeno kvantno kolo sa samo jednim blokom (oblast uokvirena isprekidanom linijom na Sl. 3) koji ima samo 8 varijabilnih parametara i računata je lokalna *функција грешке* (engl. *cost/loss function*). Parametri mreže su inicirani na pseudo-slučajan način. Broj *prolaza kroz trening skup* (engl. *epoch*) je bio 100 puta. Zatim je dodat još jedan blok, tako da je dobijeno finalno kvantno kolo prikazano na Sl. 3. Dobijene vrednosti varijabilnih parametara (zaokružene na 2 značajne cifre) za deo kvantnog kola koji je prethodno treniran su uzeti kao inicijalni, dok su parametri za blok koji

je dodat izabrani nasumično. Postepeno građenje finalne pretpostavke kvantnog kola je urađeno kako bi se pri obučavanju izbegla pojava *ravnih platoa* (engl. *barren plateaus*) funkcije greške [23-25]. Pri rešavanju problem vezanog za prepoznavanje rukom pisanih brojeva (MNIST dataset) [26], ovaj pristup je pokazao i značajno manju grešku generalizacije u odnosu na standardne šeme obučavanja, koje se primenjuju na celu mrežu [25]. Trening je urađen u 100 prolaza sa 100 uzoraka u svakom trening skupu. Dobijeni su vektori varijabilnih parametara za mreže generatora sastavljene od jednog i dva osnovna gradivna bloka, redom:

$$(a) \boldsymbol{\theta}_G = [5.3857293, 4.28779218, 4.24118702, 0.51582692, 2.21546187, 1.08074945, 4.08073098, 4.46537089].$$

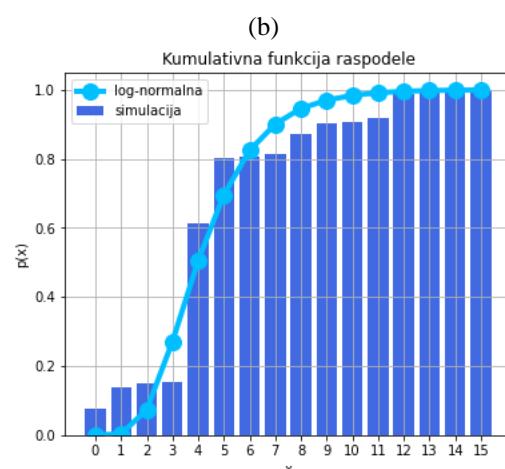
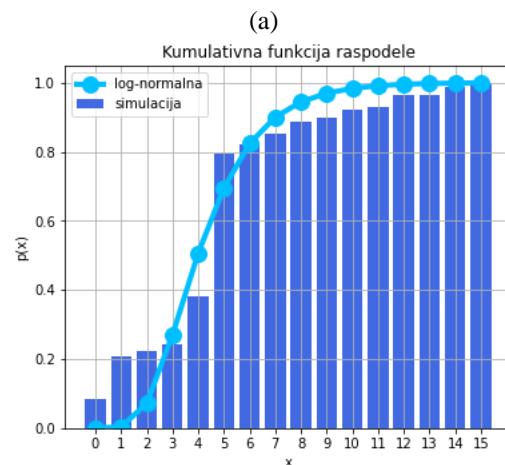
$$(b) \boldsymbol{\theta}_G = [4.13100272, 0.63322951, 5.16027858, 2.0964577, 4.03147984, 4.69264686, 5.54824841, 5.96373602, 1.69386018, 4.81546402, 1.1501217, 3.24610254].$$



Sl. 4. Evolucija funkcije greške (engl. cost/loss function) diskriminatora (svetlo plava linija) i kvantne mreže generatora (tamno plava linija), sastavljene od (a) jednog i (b) dva osnovna gradivna bloka.

Da bi analizirali tok obučavanja mreže, treba razmotriti

promenu funkcije greške u toku treninga. Evolucija funkcije greške u funkciji rednog broja koraka za mrežu sastavljenu od jednog i dva osnovna bloka je prikazana na Sl. 4 (a) i (b), redom. Za mrežu sastavljenu od jednog osnovnog bloka, vrednosti greške generatora i diskriminatora postaju uporedive posle dvadesetak koraka obučavanja. Pritom, razlika je najveća na početku treninga, što je očekivano, jer su parametri mreže inicirani na pseudo-slučajan način i mreža, inicirana na ovaj način, ne daje odgovarajuću raspodelu. U slučaju mreže koja je sastavljena od dva bloka, greška nije velika ni na samom početku treninga. Ovo je posledica postepenog građenja kvantnog kola generatora, gde smo za deo mreže inicirali skup parametara, tako da se na zadovoljavajući način reprezentuje tražena raspodela. Uočava se da u toku obučavanja greška diskriminatora približno ulazi u zasićenje, dok greška generatora "osciluje" oko neke srednje vrednosti. Razlog za ovakvo ponašanje je izbor metoda za optimizaciju Adam, koji je računski efikasan i brzo nalazi optimalno rešenje, ali ne adaptira korak na adekvatan način, tako da se postigne bolja konvergencija.



Sl. 5. Kumulativna funkcija log-normalne raspodele (svetlo-plava linija) i histogram kumulativne raspodele dobijen usrednjavanjem 10000 raspodela koje je generisao realizovani kvantni generator sastavljen od (a) jednog i (b) dva osnovna sloja kvantne mreže.

Za dobijene parametre kvantnih generatora, postavljena su kvantna kola i generisano je po 10000 raspodela. Za svaku generisanu raspodelu je nadena kumulativna funkcija raspodele i rezultati su usrednjeni. Dobijeni rezultati su upoređeni sa kumulativnom funkcijom idealizovane log-normalne raspodele, koja je ustanovljena za polazni skup i rezultati su prikazani na Sl. 5. Poređenjem raspodela na Sl. 5 (a) i (b) se može ustanoviti da jednostavnija mreža daje nešto lošije rezultate u oblasti gde postoji veliki gradijent log-normalne raspodele. Mreža generatora koja se sastojala iz više slojeva je bolje reproducirala "strmiju" raspodelu. Prepostavlja se da bi razlike između dubljih mreža (sa više od

dva osnovna kvantna sloja) i mreže sa jednim slojem bila još veća u slučaju generisanja raspodele, koja ima više lokalnih maksimuma (multimodalna raspodela). Ipak, povećanje broja slojeva bi značajno produžilo trening mreže. Treba naći ravnotežu između kompleksnosti implementacije mreže (u cilju povećanja realističnosti raspodele) generatora i vremena potrebnog za obučavanje mreže. Takođe, prepostavlja se da bi još realniji opis proizvoljne raspodele mogao da se dobije ukoliko bi se koristila kola sa više kubita, što bi dodatno usložnilo svaki sloj kvantne mreže i značajno produžilo trening i jednoslojne i višeslojne (duboke) mreže.



Sl. 6. Šematski prikaz kvantnih operacija korišćenih za implementaciju koda na kvantnom računaru ibmq_lima. Sistem ima 5 kubita raspoređenih u T geometriji, tako da je kubit q1 povezan sa tri kubita (q0, q2 i q3), kubit q3 sa dva kubita (q2 i q4), dok su ostali "ivični" kubiti (q0, q2 i q4) povezani samo sa jednim najbližim susedom.

Na kraju je metoda testirana na realnom kvantnom računaru. Kôd je izvršen na najmanje opterećenom sistemu **ibmq_lima** [27]. Ovaj sistem je zasnovan na Falcon r4T arhitekturi kvantnog procesora sa svega 5 kubita i *quantum zapreminom* (engl. quantum volume) koja iznosi 8. Iako predstavlja jedan od najsukromnijih IBM-ovih sistema po pitanju performansi, dovoljan je za izvršavanje postavljenog problema. Osnovna kvantna kola (engl. gate) u ovoj arhitekturi su jednokubitne *ID* (jedinična; engl. Identity gate), *X*, *RZ* (rotacija oko *z*-ose na Bloch-ovoj sferi), *SX* (koren iz *X*; $Sqrt(X) = \sqrt{X}$) i dvokubitna *CX* (kontrolisana *X* operacija). Realizacija jednog koraka programa odgovara implementaciji dатој на Sl. 6. Korišćena su prva 4 kubita (označeni q0-q3), pošto zadovoljavaju uslov najbolje međusobne povezanosti. Zbog ograničenog broja iteracija, koje jedan korisnik može odraditi u jednom procesu, broj epoha pri obučavanju je ograničen na 20. Ovaj broj je pet puta manji od onoga što je korišćeno u kvantnom simulatoru, pa se ne očekuje da će rezultati dobijeni na realnom kvantnom računaru biti bolji od onih na simulatoru. Kao rezultat optimizacije generatora dobijen je vektor varijabilnih parametara:

$$\Theta_G = [2.34593012, 2.40548665, 6.16308627, 0.64978231, 3.46996776, 6.22740227, 5.06966893, 2.22040949].$$

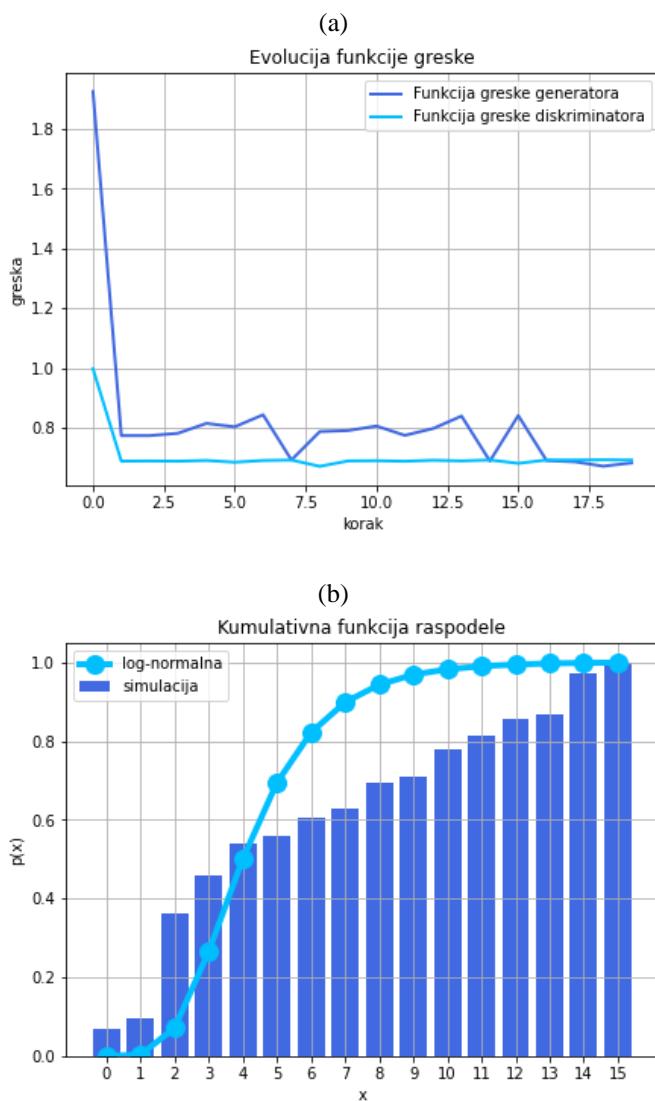
U cilju poređenja sa rezultatima, koji su dobijeni pomoću klasičnog programskog simulatora kvantnog kola, na Sl. 7 su redom prikazani evolucija funkcije greške u funkciji rednog broja iteracija (epohe) i histogram kumulativne funkcije raspodele, dobijeni na osnovu rezultata koje je generisao realni kvantni sistem. Čak i za ovako mali broj epoha pri obučavanju kvantne mreže na kvantnom računaru, kvantni generator je u stanju da "prevari" klasični diskriminator. Ovo

je očigledno na osnovu Sl. 7 (a), gde je funkcija greške generatora manja od diskriminatora posle obučavanja. Sa druge strane, poređenje kumulativne funkcije greške za log-normalnu i raspodelu dobijenu usrednjavanjem 10000 generisanih raspodela (videti Sl. 7 (b)) mogu se uočiti značajna odstupanja. Takođe, rezultati su lošiji od onih koji su dobijeni pomoću softverskog simulatora (videti Sl. 5), što je i očekivani rezultat obzirom da je obučavanje realnog hardvera bilo značajno kraće. Ono što je očigledno je da je u realnom hardveru funkcija greške pala na malu vrednost već posle par iteracija, za razliku od klasične simulacije kvantnog računanja, gde je značajan pad ostvaren tek posle 20 epoha. Ovo bi moglo da navede na pogrešan zaključak, da obučavanje kvantnog generatora realizovanog na kvantnom računaru traje kraće od vremena (broja iteracija) koje predviđa simulacija, gde nisu uračunati efekti šuma i dekoherencije. U skorašnjim publikacijama [25] se kao razlog za ovakvo ponašanje navodi prisustvo dekoherencije i šuma u kvantnom hardveru, koji su uzrok brže konvergencije ka optimalnoj vrednosti parametara.

IV. ZAKLJUČAK

U radu je razmotreno kvantno kolo generatora raspodele koji bi se mogao iskoristiti za generisanje rezultata koji odgovaraju realnim eksperimentalnim rezultatima u mnogim naučnim oblastima. Kolo je dobijeno algoritmom kvantne generativne suparničke mreže, gde se u konkurentnom postupku takmiče kvantni generator, koji generiše raspodelu, i klasična neuralna mreza, koja treba da klasificuje generisanu raspodelu kao realnu ili lažnu. Za razliku od originalne postavke algoritma, diskriminator je klasičan i treba da

reprodukuje slučaj, gde kvantni sistem treba da nadmaši klasični sistem mašinskog učenja koji se upotrebljava za otkrivanje računarski generisanih rezultata. Ustanovljeno je da je moguće realizovati kvantnu mrežu koja bi sa velikom verovatnoćom mogla da generiše raspodelu, koju bi klasični diskriminator ocenio kao realističnu. Kao primer je uzeta log-normalna raspodela, mada bi princip bio identičan i u slučaju proizvoljne raspodele.



Sl. 7. Za realni kvantni generator koji se sastoji iz jednog sloja i klasičan diskriminator prikaz: (a) evolucije funkcije greške diskriminatora (svetlo plava linija) i kvantne mreže generatora (tamno plava linija); (b) kumulativna funkcija log-normalne raspodele (svetlo-plava linija) i histogram kumulativne raspodele dobijen usrednjavanjem 10000 generisanih raspodela dobijenih pomoću kvantne mreže generatora (tamno plava linija).

Najpre je izvršena simulacija kvantnog algoritma na klasičnom računaru. Za konstrukciju generatora su korišćene kvantne mreže sa jednim i dva sloja. U svakom sloju je ostvareno kružno kvantno sprezanje kubita. Analizom evolucije greške tokom treninga i kumulativne funkcije raspodele realizovane jednoslojne i dvoslojne mreže je ustanovljeno da mreže sa više slojeva verodostojnije generišu traženu raspodelu. Ipak, sa povećanjem broja slojeva se

povećavao broj varijabilnih parametara, a samim tim i vreme potrebno za obučavanje mreže. Ustanovljeno je da obe mreže, sa velikom verovatnoćom, mogu prevariti klasičan diskriminator, koji bi vršio klasifikaciju rezultata. Zatim je algoritam izvršen na realnom kvantnom hardveru. Analiziran je kvantni generator koji se sastoji iz jednog kvantnog sloja. Obučavanje je izvršeno u malom broju koraka. Dobijeni su rezultati koji su ukazali na dobre performance razmatranog algoritma i u slučaju simulacije na realnom kvantnom računaru. Za realizaciju analiziranog algoritma nije potreban veliki broj slojeva u kvantnoj mreži, pa se obučavanje može izvesti u relativno malom broju iteracija, čak i na trenutno dostupnom kvantnom hardveru koji je podložan dekoherenciji i šumu. Analizirani algoritam bi se mogao usložniti na slučaj raspodele u više dimenzija, tako da daje rezultate koji su veoma slični onima koji bi se dobili u eksperimentalnim biomedicinskim merenjima poput citometrije, DNK analize, radiooloških, ultrazvučnih i drugih biomedicinskih mernih metoda. U daljem radu bi bilo interesantno razmotriti kako bi se model pokazao na slučajevima složenijih jednodimenzionih i višedimenzionih raspodela, kako bi povećanje broja kubita uticao na poboljšanje performansi generatora, kao i slučaj različitog sprezanja kubita u osnovnom kolu na kvalitet rezultata i vreme konvergencije parametara mreže.

ZAHVALNICA

Ovaj rad je podržan od strane Ministarstva prosvete, nauke i tehnološkog razvoja Republike Srbije 451-03-68/2022-14/200103.

LITERATURA

- [1] Y. S. Rao, "Scientific publication process and its impact on growth of science," *Ann. Lib. Inf. Stu.*, Vol. 67, pp. 13-20, Mar. 2021.
- [2] <https://dblp.org/statistics/publicationsperyear.html>
- [3] M. Mabe, "The growth and number of journals," *Serials*, vol. 16, no.2, pp. 191-197, July 2003.
- [4] S. Rawat, S. Meena, "Publish or Perish: Where are we heading?" *J. Res. Med. Sci.*, vol. 19, pp. 87-89, Feb.2014.
- [5] U. A. Hasan, G. Trinchieri, J. Vlach, "Toll-like Receptor Signaling Stimulates Cell Cycle Entry and Progression in Fibroblasts," *J. Biol. Chem.*, vol. 280, no. 21, pp. 20620-20627, May 2005.
- [6] S. Magar, D. Nayak, U. B. Mahajan, K. R. Patil, S. D. Shinde, S. N. Goyal, S. Swaminarayan, C. R. Patil, S. Ojha, C. N. Kundu, "Ultra-diluted Toxicodendron pubescens attenuates proinflammatory cytokines and ROSmediated neuropathic pain in rats," *Sci. Rep.*, vol. 8, pp. 13562 1-11, Sep. 2018.
- [7] <https://29a.ch/photo-forensics/>
- [8] <https://retractionwatch.com/>
- [9] D. P. Kingma, M. Welling, "Auto-Encoding Variational Bayes," Technical report, <https://arxiv.org/abs/1312.6114>
- [10] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, Cambridge, Massachusetts, The MIT Press, London, England, 2016.
- [11] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, "Generative adversarial networks," *Adv. Neural Inf. Process. Syst.*, vol. 27, pp. 1-9, 2014.
- [12] A. Radford, L. Metz, S. Chintala, "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," <https://doi.org/10.48550/arXiv.1511.06434>

- [13] M. A. Nielsen, I. L. Chuang, Quantum Computation and Quantum Information, 10th ed. Cambridge, United Kingdom: Cambridge University Press, 2010.
- [14] M. Schuld, F. Petruccione, Machine Learning with Quantum Computers, 2nd ed. Cham, Switzerland: Springer Nature Switzerland AG, 2021.
- [15] P.-Luk D.-Demers, N. Killoran, "Quantum generative adversarial networks," *Phys. Rev. A*, vol. 98, no. 1, pp. 012324 1-8, Jul. 2018.
- [16] S. Lloyd, C. Weedbrook, "Quantum Generative Adversarial Learning," *Phys. Rev. Lett.*, vol. 121, no. 4, pp. 040502 1-5, Jul. 2018.
- [17] H. Situ, Z. He, Y. Wang, L. Li, S. Zheng, "Quantum generative adversarial network for generating discrete distribution," *Information Sciences*, vol. 538, pp. 193-208, June 2020.
- [18] G. Agliardi, E. Prati, "Optimal Tuning of Quantum Generative Adversarial Networks for Multivariate Distribution Loading," *Quantum Rep.*, vol. 4, pp. 75-105, Feb. 2022.
- [19] H-L. Huang, Y. Du, M. Gong, Y. Zhao, Y. Wu, C. Wang, S. Li, F. Liang, J. Lin, Y. Xu, R. Yang, T. Liu, M-H. Hsieh, H. Deng, H. Rong, C-Z. Peng, C-Y. Lu, Y-A. Chen, D. Tao, X. Zhu, J-W. Pan, "Experimental Quantum Generative Adversarial Networks for Image Generation," *Phys. Rev. Appl.*, vol. 16, no. 2, pp. 024051 1-20, Avg. 2021.
- [20] <https://qiskit.org/>
- [21] https://qiskit.org/documentation/machine-learning/tutorials/04_qgans_for_loading_random_distributions.html
- [22] Diederik P. Kingma, Jimmy Ba, "Adam: A Method for Stochastic Optimization," <https://doi.org/10.48550/arXiv.1412.6980>
- [23] J. R. McClean, S. Boixo, V. N. Smelyanskiy, R. Babbush, H. Neven, "Barren plateaus in quantum neural network training landscapes," *Nat. Comm.*, vol. 8, pp. 4812 1-6, Nov. 2018.
- [24] M. Cerezo, A. Sone, T. Volkoff, L. Cincio, P. J. Coles, "Cost function dependent barren plateaus in shallow parametrized quantum circuits," *Nat. Comm.*, vol. 12, pp. 1791 1-12, Mar. 2021.
- [25] A. Skolik, J. R. McClean, M. Mohseni, P. Smagt, M. Leib, "Layerwise learning for quantum neural networks," *Quantum Mach. Intell.*, vol. 3, pp. 5 1-5, Jan. 2021.
- [26] <http://yann.lecun.com/exdb/mnist/>
- [27] https://quantum-computing.ibm.com/services?services=systems&system=ibmq_lima

ABSTRACT

For many years, we have witnessed that many publications are an effective means of recognizing exceptional competence and talent in science, which can provide an individual with great moral and financial satisfaction. The famous phrase in academic circles "publish or perish" is becoming a harsh reality. In their desire to publish sessional discoveries, individuals try to falsify scientific results to create the illusion of exceptionality. Modern image analysis programs based on artificial intelligence have proven to be an effective means of exposing false representations of scientific results and have led to the withdrawal of many suspicious publications from journals in recent years. New artificial intelligence algorithms based on generative adversarial networks provide the ability to generate images that can be classified as credible. The implementation of these algorithms on quantum computers has proven to be a potentially superior method of image generation and poses a real danger that cases of falsification of scientific results will go unnoticed. This imposes the need to soon develop a discipline that could be described as forensics of scientific results, and which would deal with unraveling the application of classical and quantum algorithms for generating results.

Quantum Generative Adversarial Networks for Generating Scientific Results

Vladimir Arsoski