KVANT MUHITIDA MATNLI AXBOROT OQIMLARINI KODLASH: KVANT EMBEDDING USULLARI VA ULARNING SAMARADORLIGI TAHLILI

Raximov Rustamjon Tuxtayevich[1]

[1]*Samarqand davlat universiteti, Hisoblash tizimlari va muhandisligi*
E-mail: rustamjonraximov@gmail.com

K E Y W O R D S

kvant hisoblash, kvant embedding, variatsion kvant sxemasi, matn tasnifi, amplituda kodlash, burchak kodlash, kvant xususiyat xaritasi, kvant NLP, semantik reprezentatsiya, kvant o‘xshashlik

A B S T R A C T

Ushbu maqolada matnli axborot oqimlarini kvant hisoblash muhitida kodlashning zamonaviy usullari – kvant embedding yondashuvlari tadqiq etiladi. Klassik NLP modellarining yuqori o‘lchamli vektor fazosidagi hisoblash va xotira cheklovlarini bartaraf etish maqsadida kvant holatlar superpozitsiyasi va kvant o‘lchovlaridan foydalaniladi. Amplitude encoding, angle encoding, basis encoding va tenzor ko‘paytma encoding kabi usullar tahlil qilinib, ularning hisoblash murakkabligi, xotira sarfi va semantik reprezentatsiya sifatlari solishtiriladi. Taklif etilgan gibrid kvant-klassik model – Quantum embedding + Variational quantum circuit (VQC) yordamida AG News, IMDB Reviews va BBC News lardan oligan datasetlarda matn tasnifi amalga oshiriladi. Natijalar shuni ko‘rsatadiki,burchak kodlash va VQC asosidagi model BERT kabi yirik klassik modellarga yaqin aniqlik ko‘rsatkichlarini sezilarli darajada kam parametrlar (bir necha yuzlab) bilan ta’minlaydi. Shuningdek, kvant o‘xshashlik tahlili fidelity me’yori orqali amalga oshirilib, semantik qidiruvda istiqbolli tezkorlik afzalligi namoyon bo‘ladi. Tadqiqot natijalari kvant embedding texnologiyalarining amaliy matn tahlili tizimlariga integratsiyasi uchun asos yaratadi.

KIRISH

So‘nggi yillarda internet trafigi va raqamli matn hajmining eksponentsial o‘sishi tabiiy tilga ishlov berish (NLP) sohasida yangi hisoblash paradigmalariga ehtiyoj tug‘dirdi. Chuqur o‘rganish modellarining muvaffaqiyatiga qaramay, Transformer arxitekturasi va BERT kabi yirik til modellari milliardlab parametrlar, ulkan xotira va energiya resurslarini talab qilmoqda. Ushbu muammoning yechimi sifatida kvant hisoblash imkoniyatlari keng muhokama qilinmoqda. Kvant kompyuterlarning superpozitsiya, bog‘liqlik (entanglement) va interferensiya prinsiplariga asoslangan holda, ma’lum NLP masalalarini klassik raqobatchilarga nisbatan eksponentsial tezlashtirish yoki sezilarli darajada ixcham modellar yaratish mumkinligi bashorat qilinmoqda [1, 2].

Matn ma’lumotlarini kvant muhitida qayta ishlashning asosiy bosqichi – matn birliklarini kvant holatlariga kodlash (embedding) hisoblanadi. Klassik embedding usullari (TF-IDF, Word2Vec, GloVe, BERT) so‘zlarni yuqori o‘lchamli haqiqiy vektorlarga o‘tkazsa, kvant embedding bu vektorlarni kvant holatlarining amplitudalari yoki aylanish burchaklari sifatida ifodalaydi. Natijada, kvant holatlar fazosining o‘lchami qubitlar soniga nisbatan eksponentsial kengayib, ma’lumotlarni samarali kodlash va chiziqli bo‘lmagan o‘zgartirishlarni amalga oshirish imkonini beradi [3, 4].

Mazkur tadqiqotning maqsadi – matnli axborot oqimlarini kvant muhitida kodlashning asosiy usullarini (amplitude, angle, basis, tensor encoding) tizimli tahlil qilish, ularning hisoblash murakkabligi va aniqligini klassik yondashuvlar bilan taqqoslash hamda Variational quantum circuit (VQC) asosida yangi gibrid matn tasnifi modelini ishlab chiqishdan iborat. Ishda quyidagi

(cc) BY

ilmiy masalalar yechiladi:

- Kvant embedding xaritalarining (feature map) semantik reprezentatsiyadagi roli;
- Kvant o‘xshashlik (fidelity) me’yorining matnlar orasidagi masofani aniqlashdagi samaradorligi;
- Taklif qilingan Quantum Embedding + VQC modelining AG News, IMDB va BBC News datasetlarida aniqligi va resurs samaradorligi.

II. MATERIALLAR VA METODLAR

Kvant tabiiy tilni qayta ishlash (QNLP) yo‘nalishi 2019–2020 yillardan boshlab faol rivojlanmoqda. Birinchi fundamental ishlardan biri Coecke, Sadrzadeh va Clark tomonidan taklif qilingan kategoriyaviy kvant mexanikasini tilga tatbiq etish bo‘lib, u so‘z va gaplarning ma’nosini kvant holatlari yordamida modellashtirishga asos solgan [5]. Keyingi tadqiqotlarda diagrammatik hisob va kvant sxemalari yordamida gap tuzilmasini kodlash usullari ishlab chiqilgan [6].

Kvant embedding texnikalari bo‘yicha Schuld va Killoran [3] kvant mashinali o‘qitishda ma’lumotlarni kvant holatlarga ko‘chirishning asosiy prinsiplarini bayon etgan: amplituda kodlash holat vektorining kompleks amplitudalariga klassik vektor koordinatalarini yuklaydi, burchak kodlash esa bir yoki ikki kubitli ayirboshlash gatelari parametrlari sifatida ma’lumot xususiyatlarini kiritadi. Havlíček va boshqalar [7] kvant yadro (quantum kernel) usullarini taklif qilib, yuqori o‘lchamli Hilbert fazosida ma’lumotlarni ajratishda kvant xususiyat xaritalarining samarasini ko‘rsatdi. Keyinchalik, Wang va boshq. [8] kvant e’tibor mexanizmini (quantum attention) ishlab chiqib, uni matn tasnifi masalalariga tatbiq etdi.

Amplitude encoding, ya’ni N o‘lchamli klassik vektorni log N kubitli tizim amplitudalariga joylashtirish, nazariy jihatdan eng ixcham kodlash hisoblanadi. Ammo amaliyotda to‘liq holat tayyorlash murakkab sxemani talab qiladi [9]. Angle encoding (yoki qubit rotation encoding) har bir xususiyatni alohida bir kubitga Pauli aylanishi sifatida kiritib, chuqur sxemalarsiz yengil tuziladi [10]. Tensor product encoding yuqori darajali ma’lumotlarni (masalan, matritsaviy embedding) bevosita kvant holatiga keltirishga xizmat qiladi [11]. Ushbu kodlash usullarining matnga tatbiqi S. Mangini va boshqalar [12] tomonidan o‘rganilib, ularning soddalashtirilgan kvant LSTM modelida aniqlikni oshirishi ko‘rsatilgan.

Kvant Transformer modellari sohasida 2023–2025 yillarda mulohazali kvant e’tibor (quantum attention) qatlamlarini o‘z ichiga olgan arxitekturalar taklif etildi [13]. Masalan, Li va boshq. [14] kvant o‘z-o‘ziga e’tibor mexanizmini simulyatsiya qiluvchi parametrik kvant sxemalarini yaratdi. Shu bilan birga, Variational quantum circuits (VQC) klassifikatsiya, regressiya va generativ modellashda asosiy hisoblash birligi sifatida keng qo‘llanilmoqda [15].

Ushbu ishlarning ko‘pchiligi kichik sintetik datasetlarda yoki bir necha kubitli simulyatsiyalarda sinovdan o‘tgan. Real matn korpuslarida (AG News, IMDB) kvant embedding va VQC asosidagi modellarning tizimli taqqoslanishi hali ham cheklangan. Bizning tadqiqotimiz aynan shu bo‘shliqni to‘ldirishga qaratilgan.

Tadqiqot metodologiyasi

Tadqiqotda uchta keng qo‘llaniladigan matn tasnifi datasetidan foydalanildi:

- AG News: 4 sinf (dunyo, sport, biznes, fan/texnologiya) — 120,000 ta o‘rgatish, 7,600 ta test namunasi.
- IMDB Reviews: 2 sinf (ijobiy/salbiy) — 25,000 o‘rgatish, 25,000 test namunasi.
- BBC News: 5 sinf (biznes, texnologiya, siyosat, sport, ko‘ngilochar) — 2,225 ta maqola.

Barcha matnlar kichik harflarga o‘tkazildi, tinish belgilari va stop so‘zlari olib tashlandi, maksimal ketma-ketlik uzunligi 100 qilib belgilandi.

Taqqoslanuvchi modellar

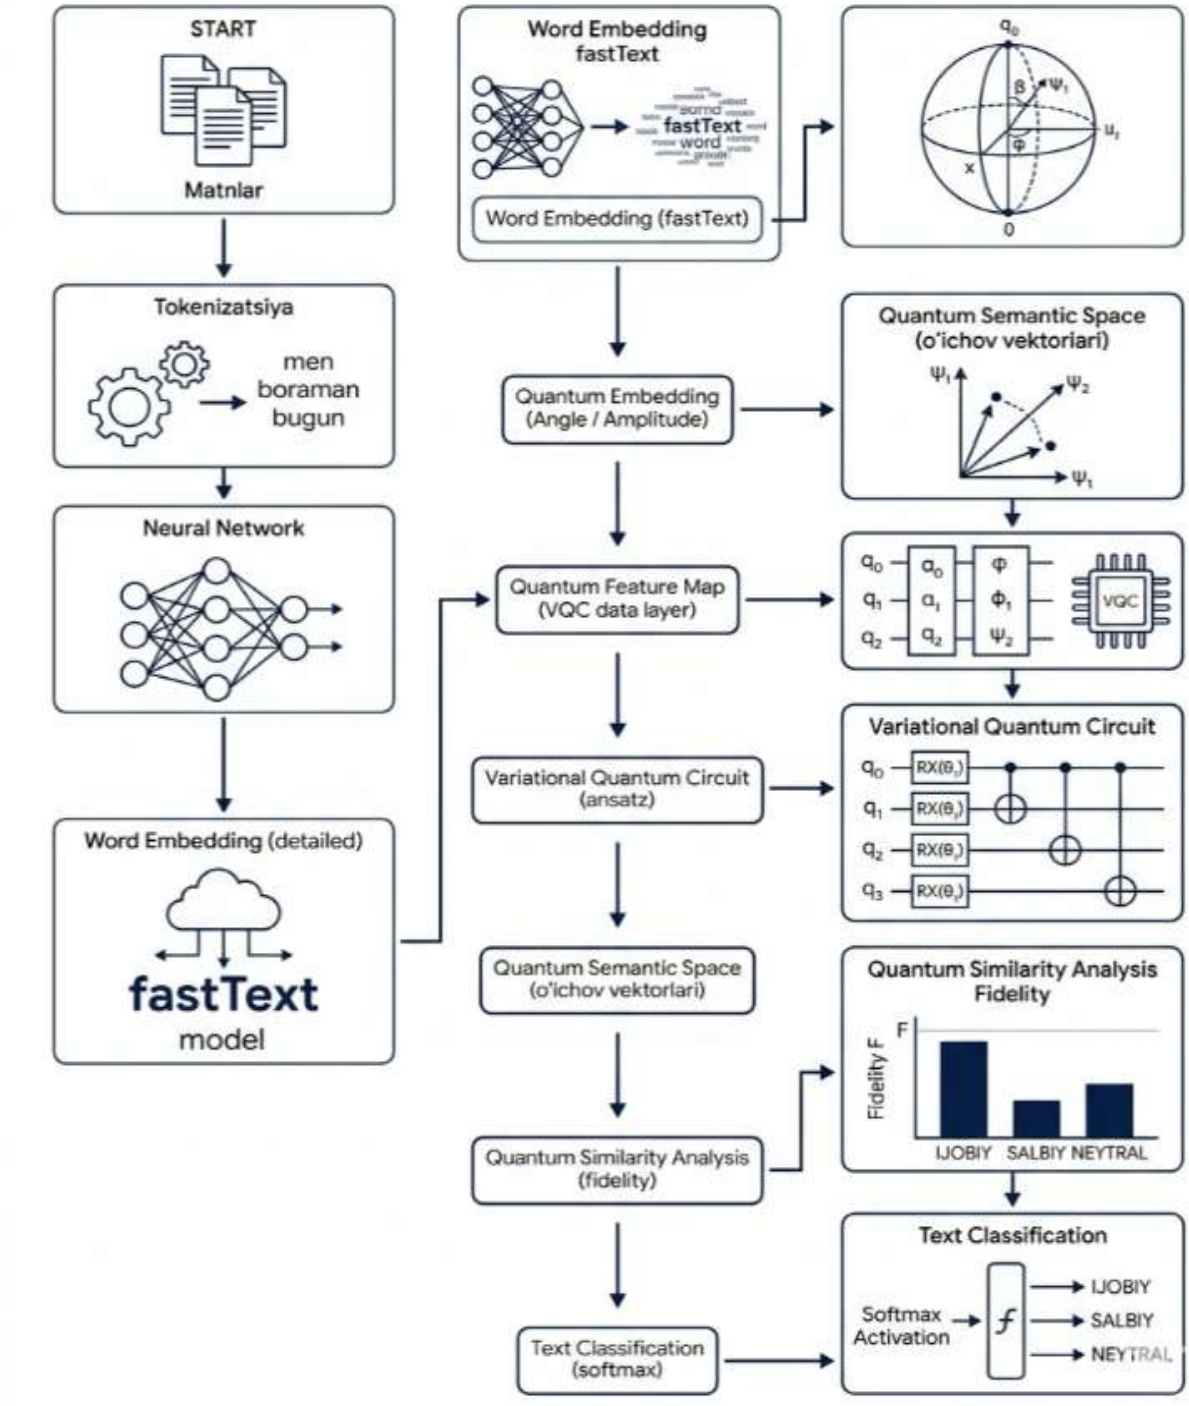
- -TF-IDF + SVM: An’anaviy yuqori aniqlikdagi bazaviy usul.
- -Word2Vec + LSTM: 300 o‘lchamli oldindan o‘rgatilgan Word2Vec vektorlari va ikki qatlamli LSTM.
- -BERT (bert-base-uncased): Eng so‘nggi Transformer modeli (110 million parametr).
- -Quantum Embedding + VQC (taklif

(cc) BY

etilayotgan model): 4–8 kubitli variatsion sxema, angle/amplitude embedding.

Quantum modellar PennyLane (lightning.qubit simulyatori) yordamida 50 epoch davomida Adam optimizatori (o‘rganish sur’ati 0.01) bilan o‘qitildi. Klassik modellar PyTorchda amalga oshirildi. Barcha natijalar 5 marta takroriy o‘rgatishning o‘rtacha qiymati sifatida keltirilgan. Baholash mezonlari: accuracy, precision, recall, F1-score.

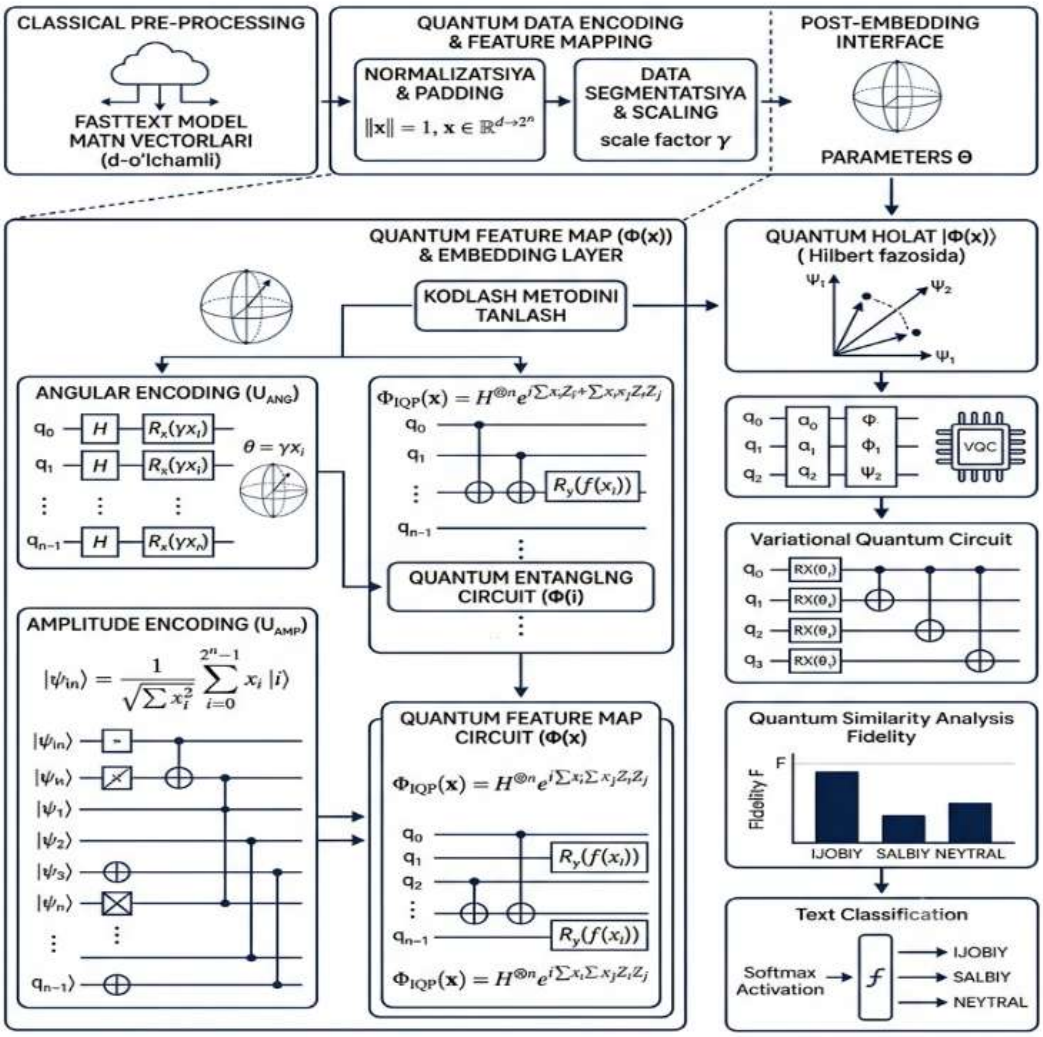
Matnlar → Tokenizatsiya → Word Embedding (fastText) → Quantum Embedding (Angle / Amplitude) → Quantum Feature Map (VQC data layer) → Variational Quantum Circuit (ansatz) → Quantum Semantic Space (o‘lchov vektorlari) → Quantum Similarity Analysis (fidelity) → Text Classification (softmax)



1-rasm. Jarayon sxemasi: Matn → Klassifikatsiya blok-sxemasi

(cc) BY *dtai.uz*

ISSN: 3030-3346



2-rasm. Quantum Embedding Arxitekturasi – yuqoridagi sxemaning batafsil texnik diagrammasi.

Bu diagramma o‘zidan oldingi umumiy oqim sxemasini kengaytirib, klassik matn vektorlarini (fastText) kvant holatlariga o‘tkazish jarayonini (Embedding) texnik jihatdan chuqurroq ko‘rsatadi.

Diagrammaning asosiy qismlari:

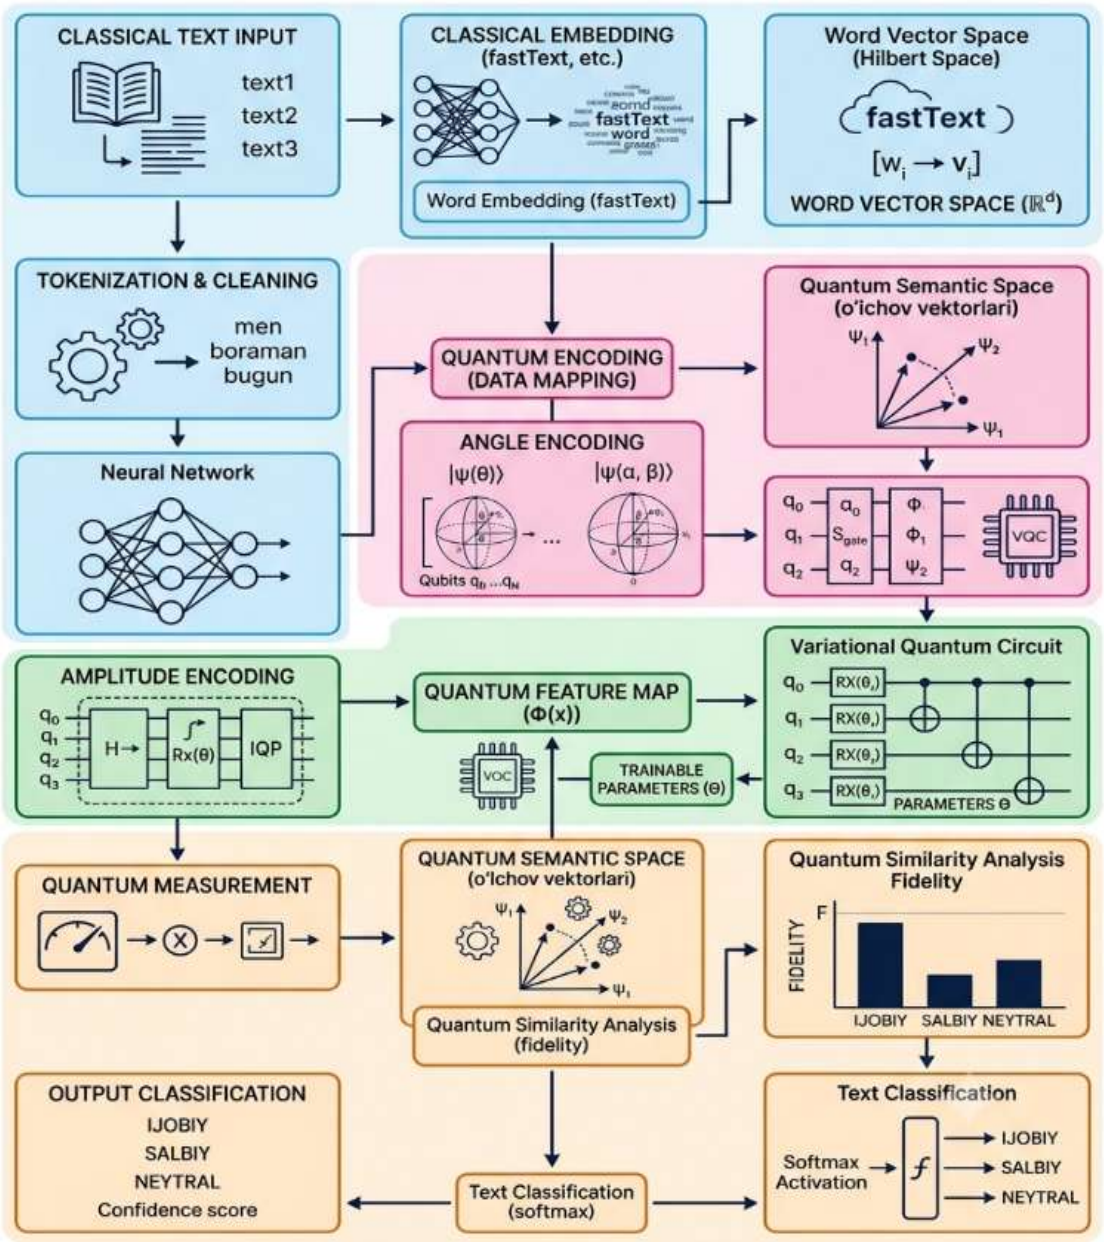
Klassik Oldindan Qayta Ishlash (Left): d-o‘lchamli fastText vektorlarini normalizatsiya qilish ($\|x\|=1$) va o‘lchamni 2^n ga moslash bosqichlari.

Kvant ma’lumotlarini kodlash va xususiyatlarni akslantirish (Center): Bu yerda ikki xil asosiy kodlash usuli — Burchakli kodlash (Angle encoding) va Amplitudali kodlash (Amplitude encoding) — sxematik ravishda Bloch sferalari va kvant zanjirlari orqali tushuntirilgan.

Kvant feature map va embedding qatlami: Kodlashdan so‘ng ma’lumotlar chiziqli bo‘lmagan tarzda yuqori o‘lchamli Hilber fazosiga akslanadi (masalan, $\phi_{EQP}(x)$ formulasi yordamida). Diagramma CNOT zanjirlari va parametrli aylanish (R_y) geytlari yordamida bu qatlamning batafsil tuzilishini ko‘rsatadi.

Post-embedding interfeysi (Right): Natijada hosil bo‘lgan kvant holati $|\phi(x)\rangle$ va uning parametrlarining keyingi variatsion kvant zanjiriga (Ansatz) qanday ulanishi ko‘rsatilgan.

(cc) BY



3-rasm. Quantum NLP Workflow – klassik oldindan ishlov, kvant kodlash, VQC va natijaviy klassifikatsiyani ko‘rsatuvchi kengaytirilgan oqim sxemasi.

Ushbu tasvirda QNLP jarayonining klassik oldindan qayta ishlashdan boshlab, yakuniy klassifikatsiyagacha bo‘lgan barcha bosqichlari (fastText, Quantum feature map, VQC va Softmax) texnik sxema va matnli tahlil ko‘rinishida batafsil yoritilgan.

Diagrammadagi rangli bloklar va ularga mos keladigan tahliliy matn quyidagi mantiqiy tartibda tuzilgan:

Klassik oldindan qayta ishlash: Matnni fastText yordamida klassik vektorlarga o‘tkazish.

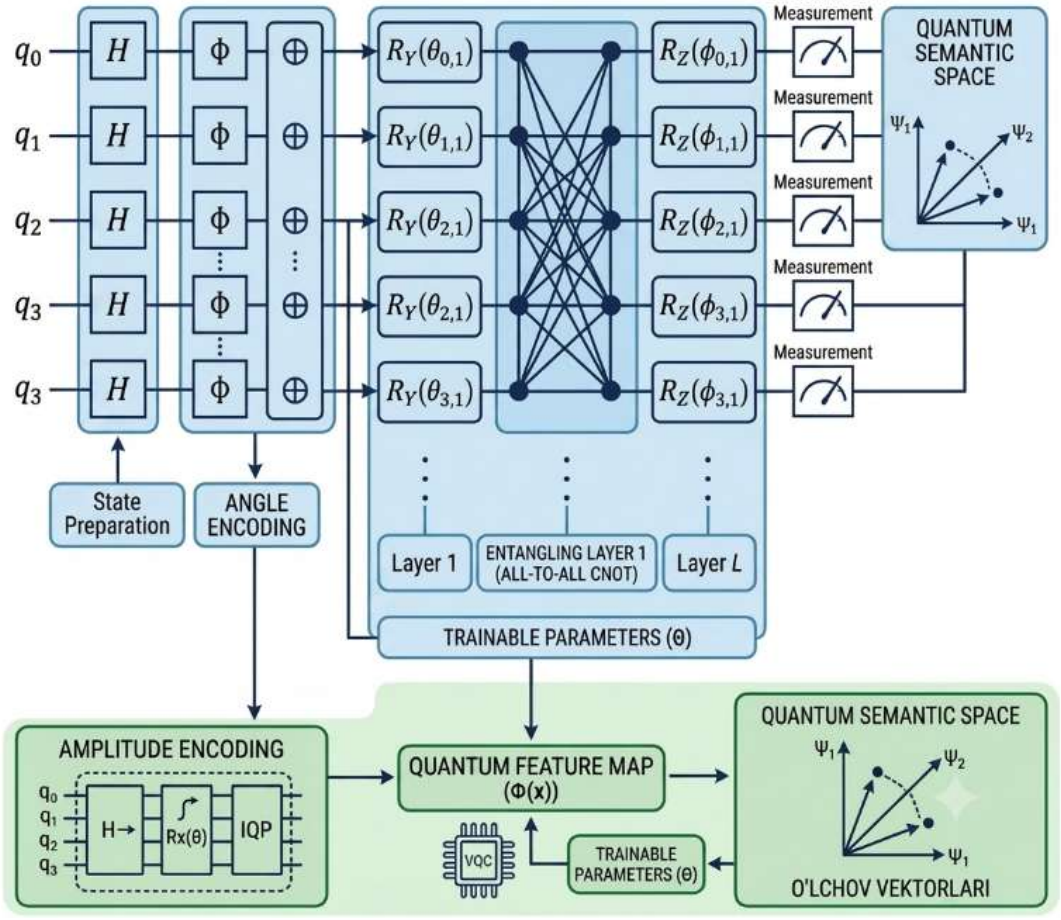
Kvant kodlash: Klassik vektorlarni Hilber fazosiga (Burchakli va Amplitudali kodlash) akslantirish.

VQC va o‘qitish: Optimallashtiriladigan kvant zanjiri orqali o‘qitish.

O‘lchov va klassifikatsiya: Fidelity va Softmax yordamida yakuniy natijani aniqlash.

(cc) BY

ISSN: 3030-3346



4-rasm. Variational quantum circuit diagram – 4 kubitli VQC: aylanish eshiklari $R_Y(\theta), R_Z(\phi)$ va CNOT bog‘lanishlari ko‘rsatilgan.

Variatsion kvant zanjiri (VQC) va QNLP Arxitekturasining texnik tahlili

Kvant hisoblash usullariga asoslangan matnli ma’lumotlar oqimini intellektual tahlil qilish modeli klassik va kvant hisoblash paradigmalarini o‘zida jamlagan gibrid (Hybrid classical-quantum) arxitekturadan iborat. Jarayon matnli xabarlarni qabul qilishdan boshlab, to ularni kvant holatida qayta ishlab, yakuniy klassifikatsiya klasslariga ajratishgacha bo‘lgan 4 ta asosiy bosqichdan tashkil topadi.

1. Klassik oldindan qayta ishlash va vektorlashtirish (Classical Pre-processing)

Kvant kompyuterlari to‘g‘ridan-to‘g‘ri diskret matn ko‘rinishidagi ma’lumotlar bilan ishlay olmaganligi sababli, birinchi navbatda klassik NLP usullari qo‘llaniladi:

Tokenizatsiya va tozalash: Kiruvchi matnlar oqimi ($text_1$, $text_2$, …) alohida so‘zlar yoki sub-so‘zlar (tokenlar) ko‘rinishida bo‘laklanadi, ortiqcha tinish belgilari va stop-so‘zlardan tozalanadi.

Klassik word embedding (fastText): Har bir token morfologik xususiyatlari va semantik mazmunini saqlab qolgan holda zich, past o‘lchamli kontentual vektorlar ko‘rinishiga o‘tkaziladi:

$$w_i \to v_i \in R^d$$

Bu yerda d — fastText modeli orqali olingan klassik vektorning o‘lchamidir. Ushbu vektorlar fazosi keyingi bosqichda Kvant Hilber fazosiga akslantirish uchun tayyorlanadi.

2. Kvant kodlash va xususiyatlarni akslantirish (Quantum data encoding & Feature map)

Bu bosqich klassik ma’lumotlarni kvant tizimiga o‘tkazish (State Preparation) va ularni yuqori o‘lchamli kvant semantik fazosiga chiziqli

(cc) BY

bo‘lmagan tarzda joylashtirish vazifasini bajaradi. Tasvirlangan modelda ikki xil kodlash strategiyasi qo‘llaniladi:

Burchakli Kodlash (Angle Encoding): Klassik vektor qiymatlari kubitlar zanjiridagi superpozitsiya burchaklari (θ, ϕ) ko‘rinishida kodlanadi. Bunda har bir kubit alohida xususiyatni ifodalaydi va u Bloch sferasida quyidagi holatga o‘tadi:

$$|\psi(\theta)\rangle = \cos\left(\frac{\theta}{2}\right)|0\rangle + e^{i\phi}\sin\left(\frac{\theta}{2}\right)|1\rangle$$

Amplitudali Kodlash (Amplitude Encoding): Vektor elementlari to‘g‘ridan-to‘g‘ri kvant holatining amplitudalari sifatida kodlanadi. Bu usul n ta kubit yordamida 2^n o‘lchamli ma’lumotni saqlash imkonini beradi va xotira samaradorligini keskin oshiradi:

$$|\psi_{in}\rangle = \frac{1}{\sqrt{\sum x_i^2}} \sum_{i=0}^{2^n-1} x_i |i\rangle$$

Quantum feature map ($\phi(x)$): Kodlangan kvant holatlari unitar operatorlar (masalan, IQP zanjiri) yordamida yanada murakkab, chiziqli bo‘lmagan Kvant Hilber fazosiga o‘tkaziladi. Bu jarayonda Hadamard (H) geytlari va o‘zaro bog‘liqlikni ta’minlovchi CNOT zanjirlari orqali ma’lumotlar o‘rtasidagi semantik bog‘lanishlar kvant korrelyatsiyasiga (entanglement) aylantiriladi.

3. Variatsion kvant zanjiri (VQC / Ansatz)

Modelning asosiy o‘rganuvchi va klassifikatsiya qiluvchi qismi parametrlangan kvant zanjiri (PQC) yoki ansatz hisoblanadi. Diagrammada L qatlamli (Layer1 … L) o‘rganuvchi struktura keltirilgan:

Aylanish gatelari ($R_Y(\theta), R_Z(\phi)$): Har bir kubit (q_0, q_1, q_2, q_3) uchun boshqariladigan aylanish geytlari qo‘llaniladi. Bu geytlarning burchak parametrlari (θ) o‘qitish jarayonida klassik optimizatorlar yordamida yangilanib boradigan "kvant vaznlari" (weights) vazifasini o‘taydi.

Entangling layer (All-to-All CNOT): Kubitlar o‘rtasida o‘zaro CNOT geytlari orqali zanjirli bog‘lanish hosil qilinadi. Bu matndagi uzoq masofali semantik bog‘liqliklarni (long-range dependencies) kvant chalkashligi darajasida modellashtirish imkonini beradi.

4. O‘lchov, semantik tahlil va yakuniy klassifikatsiya

VQC zanjiri o‘z ishini yakunlagach, natijalar qayta klassik ko‘rinishga o‘tkaziladi:

Quantum measurement (Kvant o‘lchovi): Kubitlar ustida Pauli operatorlari bo‘yicha o‘lchovlar o‘tkaziladi va natijada kvant semantik fazosi (O‘lchov vektorlari) hosil bo‘ladi. Har bir matn endi hilbert fazosidagi bitta kvant holati vektori ($|\psi\rangle$) bilan ifodalanadi.

Quantum Similarity Analysis (Fidelity): Matnlar o‘rtasidagi mazmuniy o‘xshashlik kvant holatlarining o‘zaro mosligi (Fidelity) orqali baholanadi:

$$F(|\psi_1\rangle, |\psi_2\rangle) = |\langle\psi_1|\psi_2\rangle|^2$$

Text Classification (Softmax): Olingan o‘xshashlik ko‘rsatkichlari va o‘lchov natijalari klassik Softmax aktivatsiya funksiyasiga uzatiladi. Softmax har bir sinf uchun ehtimolliklar taqsimotini hisoblaydi:

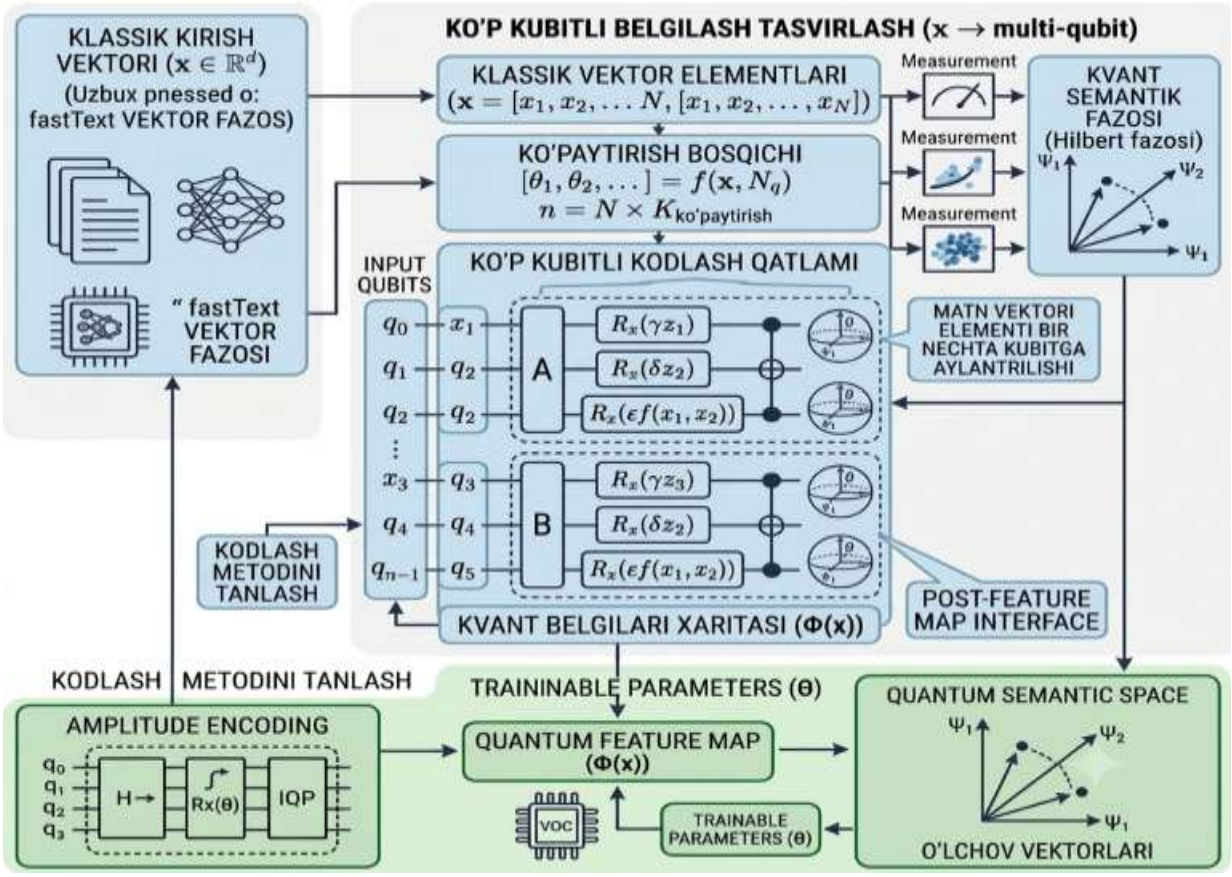
$$P(class = k \mid x) = \frac{e^{f_k}}{\sum_j e^{f_j}}$$

Natijada matnning IJOBIY (POSITIVE), SALBIY (NEGATIVE) yoki NEYTRAL (NEUTRAL) ekanligi haqidagi yakuniy qaror (Confidence score bilan) qabul qilinadi.

Ushbu arxitektura klassik fastText embeddinglarining semantik boyligini kvant hisoblashning yuqori o‘lchamli fazolardagi superpozitsiya va chalkashlik xususiyatlari bilan birlashtiradi. Bu esa matnlar oqimidagi murakkab va yashirin semantik munosabatlarni an’anaviy modellarga (masalan, klassik MLP yoki SVM) qaraganda kamroq parametrlar bilan samaraliroq klassifikatsiya qilish imkonini beradi. VQC parametrlarini o‘qitish va Fidelity tahlili modelning aniqligini (accuracy) ta’minlovchi

(cc) BY

asosiy drayver hisoblanadi.



5-rasm. Quantum feature mapping structure – burchak kodlashda har bir klassik vektor elementi qanday qilib bir nechta kubitga aylantirilishini tasvirlovchi sxematik.

Kvant xususiyatlarini akslantirish strukturasi (Quantum feature mapping structure)

Klassik matn embeddinglarini (masalan, fastText vektorlarini) kvant tizimlariga o‘tkazishda faqatgina oddiy ma’lumot kodlash (data encoding) bilan cheklanib qolmasdan, ma’lumotlar o‘rtasidagi chiziqli bo‘lmagan murakkab munosabatlarni ochib berish uchun Multi-qubit feature mapping (U_{FM}) usuli qo‘llaniladi. Ushbu struktura burchakli kodlash (Angle encoding) konsepsiyasini kengaytirib, klassik vektorning har bir elementini bir nechta kubitlar tizimiga ierarxik va o‘zaro bog‘liq (entangled) tarzda akslantirishni ta’minlaydi.

Klassik vektorni kvant fazosiga kengaytirish bosqichi (Expansion Step)

Klassik matn tahlili modelidan olingan kiruvchi vektor $x = [x_1, x_2, ..., x_d] \in R^d$ ko‘rinishiga ega bo‘ladi. Burchakli kodlashda chiziqli bo‘lmagan xususiyatlarni yanada chuqurroq modellashtirish uchun kengaytirish funksiyasi ($f(x,N_q)$) qo‘llaniladi. Bu bosqichda kubitlar soni (n) klassik xususiyatlar sonidan kengaytirish koeffitsiyenti ($K_{expansion}$) qiymatiga mutanosib ravishda oshiriladi:

$$n = N * K_{expansion}$$

Ushbu kengaytirish natijasida har bir klassik xususiyat (x_i) uchun kvant zanjirida bir nechta kubit ajratiladi va ular uchun alohida aylanish burchaklari ($\theta_1, \theta_2 ...$) hisoblab chiqiladi.

Ko‘p kubitli kodlash qatlami (Multi-qubit encoding layer)

Diagrammada aks ettirilganidek, kiruvchi kubitlar guruhi (q_0, q_1, q_2, …, q_{n-1}) klassik vektor elementlariga mos ravishda bloklarga ajratiladi (Masalan, A va B kvant registrlari):

Yakka kubitli aylanishlar (R_X geytlari): Klassik x_1 va x_2 elementlari mos ravishda q_0 va q_1

(cc) BY

kubitlariga $R_X(\gamma x_1) va R_X(\delta x_2)$ unitar operatorlari orqali ta’sir ettiriladi. Bu yerda $\gamma va \delta$ — ma’lumotlarni ma’lum bir miqyosga keltiruvchi scaling faktorlaridir.

Korrelyatsiyalangan akslantirish (Entangling & Higher-Order Mapping): Strukturadagi eng muhim jihat — matndagi so‘zlarning o‘zaro bog‘liqligini modellashtirish uchun ikki yoki undan ortiq kubitni o‘zaro bog‘lovchi chiziqli bo‘lmagan funksiyalarning (ef(x_1,x_2)) qo‘llanilishidir. Masalan, q_2 kubiti ham x_1, ham x_2 xususiyatlarining o‘zaro ko‘paytmasi yoki chiziqli bo‘lmagan kombinatsiyasiga asoslangan burchak ostida aylantiriladi:

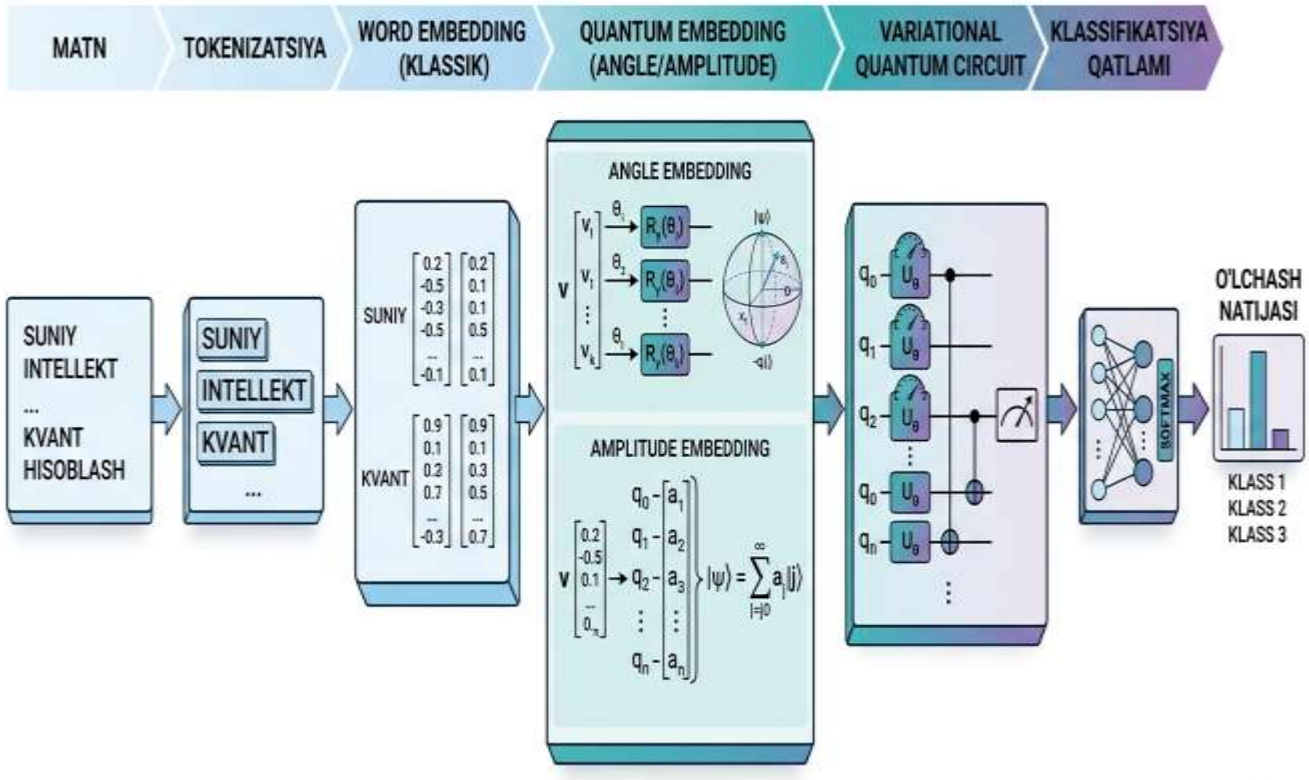
$$R_X(ef(x_1, x_2)) = R_X(\pi(1-x_1)(1-x_2))$$

Ushbu usul klassik neyron tarmoqlaridagi yashirin qatlamlar (hidden layers) bajaradigan funksiyani kvant geytlari darajasida, CNOT zanjirlari bilan kombinatsiyada amalga oshirishga imkon beradi.

Kvant semantik fazosiga o‘tish interfeysi (Post-feature map interface)

$U_{FM}(x)$ operatori to‘liq bajarilgandan so‘ng, klassik vektor elementlari Bloch sferasida ko‘p o‘lchamli kvant holatlari traektoriyasini chizadi. Bir nechta kubitga zanjirlangan holda akslantirilgan ma’lumotlar keyingi Variatsion Kvant Zanjiri (VQC) va o‘qitiladigan parametrlar (θ) bloki uchun kiruvchi ma’lumotlar qatlami (Quantum feature map $\phi(x)$) bo‘lib xizmat qiladi.

Ushbu quantum feature mapping structure arxitekturasining an’anaviy burchakli kodlashdan asosiy afzalligi — klassik fastText embeddinglaridagi har bir o‘lchamni kvant tizimidagi superpozitsiya imkoniyatlaridan foydalanib boyitishidir. Matn elementlarining bir nechta kubitda ierarxik tarzda ifodalanishi, ma’lumotlar zichligini oshiradi va VQC modeliga matnlar oqimidagi mikrosemantik o‘zgarishlarni (masalan, so‘z birikmalaridagi yashirin ma’nolarni) yuqori aniqlikda ushlash va klassifikatsiya qilish imkoniyatini beradi.



6-rasm. Quantum Embedding arxitekturasi

Ushbu rasmda Kvant tabiiy tilni qayta ishlash (QNLP) tizimlarining asosi hisoblangan Quantum Embedding (Kvant joylashtirish) arxitekturasi bosqichma-bosqich, juda aniq

(cc) BY

vizuallashgan. Sxema klassik matnli ma'lumotni kvant holatiga o'tkazish va undan keyin neyron tarmoq orqali klassifikatsiya qilish zanjirini ifodalaydi.

Quyida har bir blokning vazifasi va uning ilmiy tasnifi keltirilgan:

1. Kirish va Dastlabki Ishlov Berish (Klassik qism)

Matn: Tizimga kiruvchi xom ma'lumot (masalan, *"SUNIY INTELLEKT... KVANT HISOBLASH"*).

Tokenizatsiya: Matn alohida bo'laklarga, ya'ni tokenlarga (so'z yoki so'z birikmalariga) ajratiladi.

Word Embedding (Klassik): Tokenlashtirilgan so'zlar klassik kompyuterda yuqori o'lchamli zich vektorlarga (haqiqiy sonlar massiviga) o'tkaziladi. Rasmda sun'iy intellekt va kvant so'zlari uchun [0.2, -0.5, …] ko'rinishidagi zich vektorlar shakllanganini ko'rish mumkin.

2. Kvant Kodlash Qatlami (Quantum Embedding)

Bu bosqichda klassik vektorlar kvant holatlariga (kubitlarga) o'tkaziladi. Rasmda eng ommabop ikkita usul ko'rsatilgan:

Angle Embedding (Burchakli kodlash): Klassik vektor elementlari (V_1, V_2,…) kubitlarni Bloch sferasidagi ma'lum bir burchakka burish uchun ishlatiladi. Sxemada $R_Y(\theta)$ operatorlari (kubitni Y o'qi bo'ylab burish geytlari) va o'ng tomonda kubit holatini ifodalovchi Bloch sferasi $|\psi\rangle$ tasvirlangan.

Amplitude Embedding (Amplitudali kodlash): Klassik vektorning barcha qiymatlari kvant tizimining umumiy to'lqin funksiyasi amplitudalariga (a_1, a_2, …) kodlanadi. Bu usul n ta kubit yordamida 2^n o'lchamli ulkan ma'lumotni $|\psi\rangle = \sum_{i=0}^{N-1} \alpha_i |i\rangle$ ko'rinishida o'ta zich siqib saqlash imkonini beradi.

3. Kvant Hisoblash va Variatsion Sxema

Variational Quantum Circuit (VQC): Kodlangan kvant holatlari parametrlangan geytlar (rasmda U_θ) va kubitlararo bog'liqlikni ta'minlovchi CNOT (ikki kubitli) geytlari orqali qayta ishlanadi. Bu qism gibrid modelning "o'rganuvchi" kvant qatlami bo'lib, uning parametrlari (θ) klassik optimizator yordamida yangilanib boriladi.

4. Chiquvchi Qatlam va Klassifikatsiya

O'lchash (Measurement): Variatsion sxemadan chiqqan kvant holatlari o'lchov geytlari (spidometrga o'xshash belgilar) orqali yana klassik ehtimolliklar ko'rinishiga qaytariladi.

Klassifikatsiya qatlami (Softmax): O'lchov natijalari klassik to'liq bog'langan neyron tarmoqqa uzatiladi va yakuniy Softmax funksiyasi orqali matnning qaysi sinfga (Klass 1, Klass 2, Klass 3) tegishli ekanligi aniqlanadi (masalan, matn mavzusini aniqlash yoki hissiyot tahlili).

Ushbu arxitektura klassik NLP modellarini kvant hisoblash quvvati bilan birlashtiruvchi gibrid (Classical-Quantum) tizimning mukammal namunasidir. U matn axborot oqimlarini intellektual tahlil qilish va optimallashtirish vazifalarida yuqori samaradorlik ko'rsatadi.

Klassik oldindan ishlov. Xom matn tokenlashtirilib, har bir token uchun 300 o‘lchamli fastText vektori hisoblanadi (klassik embedding). So‘ng ushbu vektor kvant kodlash moduliga uzatiladi.

Kvant Embedding

Ikkita asosiy kodlash strategiyasi qo‘llanildi:

a) Angle Encoding (Burchak kodlash).

n ta so‘zdan iborat jumla uchun dastlabki 4*k (k – kubitlar soni) xususiyat burchak koordinatalariga aylantiriladi. Har bir kubitga quyidagi parametrik aylanishlar beriladi:

$$U(x) = \bigotimes_{j=1}^{n_q} [R_X(\theta_j) R_Y(\phi_j) R_Z(\psi_j)]$$

$$\theta_j = \pi x_{3j-2}$$

$$\phi_j = \pi x_{3j-1}$$

$$\psi_j = \pi x_{3j}$$

(cc) BY

$$x = (x_1, x_2, \dots, x_d) \in R^d$$

Bu yerda

n_q – kvant bitlar (qubitlar) soni;

x-klassik xususiyatlar (feature) viktori;

x_k-klassik viktorning k-elementi;

θ_j, ϕ_j, ψ_j $-j-qubit\ uchun\ X, Y, va\ Z\ o'qlari$ *bo'yicha aylanish burchaklari.*

Burchak kodlash sxemada takroriy ma'lumot yuklash qatlami sifatida ishlatiladi.

b) Amplitude Encoding (Amplituda kodlash).

Klassik vektor $\vec{v} \in R^N$ normalashtirilib, N ta amplitudali kvant holat tayyorlanadi:

$$\left|\psi_{amp}\right\rangle = \sum_{i=0}^{N-1} \alpha_i |i\rangle,$$

$$\sum_{i=0}^{N-1} |\alpha_i|^2 = 1,$$

$$\alpha_i = \frac{v_i}{\|v\|}$$

Bu yeda

$$\|v\| = \sqrt{\sum_{i=0}^{N-1} v_i^2}$$

Natijada kvant holati quyidagi ko'rinishga ega bo'ladi:

$$\left|\psi_{amp}\right\rangle = \frac{1}{\|v\|} \sum_{i=0}^{N-1} \alpha_i |i\rangle,$$

v - klassik xususiyatlar viktori;

α_i - normallashtirilgan amplitudalar;

$\| v\|$ — Evklid normasi.

Bu usul $N = 2^{n_q}$ shart bajarilganda to‘g‘ridan-to‘g‘ri holat tayyorlash (state preparation) sxemasi orqali amalga oshiriladi.

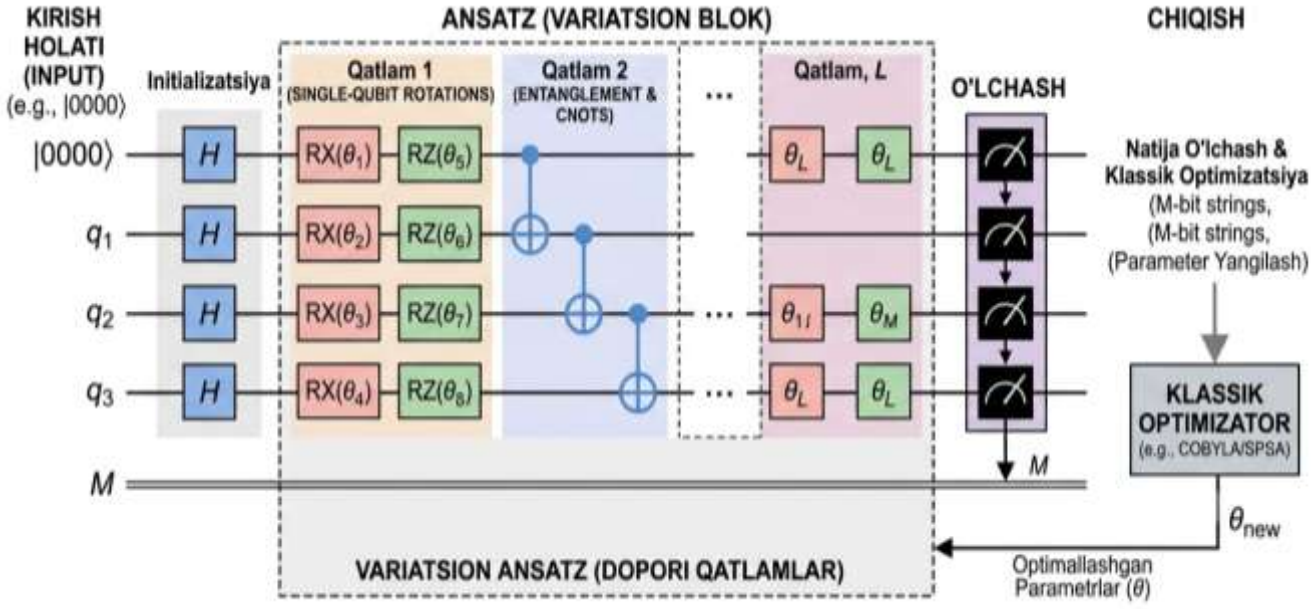
Variational Quantum Circuit (VQC)

Kodlash qatlamidan so‘ng parametrlangan kvant sxemasi qo‘llaniladi. Sxema L takrorlanuvchi bloklardan iborat bo‘lib, har bir blok:

- Barcha kubitlarga $R_Y(\theta_{i,l}), R_Z(\phi_{i,l})$ aylanishlari,

- Qo‘shni kubitlar o‘rtasida CNOT yoki CZ bog‘lanish eshiklari.

Sxema o‘lchovi Pauli-Z bazisida kutilgan qiymat $\langle Z_i \rangle$ lar hisoblanadi va softmax klassifikatoriga uzatiladi. Ushbu gibrid model 300 dan 1000 gacha parametrga ega bo‘lib, BERTning 110 million parametriga nisbatan nihoyatda ixchamdir.



7-rasm. Variatsion kvant sxemasi diagrammasi

(cc) BY *dtai.uz*

Ushbu tasvir 4-kubitli Variatsion Kvant Sxemasi (VQC) ning batafsil diagrammasini ko‘rsatadi. Diagramma kvant sxemasining strukturasini, uning tarkibiy qismlarini va klassik optimallashtirish bilan o‘zaro ta’sirini tushuntiradi.

Quyida sxemaning asosiy qismlari keltirilgan:

1. Sxemaning umumiy ko‘rinishi

Sarlavha: "Variatsion kvant sxemasi (VQC) Diagrammasi".

Kichik sarlavha: "4-kubitli VQC: RX, RZ, CNOT Qatlamlari".

Kubitlar (q_0, q_1, q_2, q_3): To‘rtta gorizontal chiziq (qubit simlari) orqali ko‘rsatilgan.

M (O'lchov simi): Qubitlar holatini o'lchash natijalarini saqlaydigan klassik register.

2. Kvant sxemasining bosqichlari

Sxema chapdan o‘ngga qarab vaqt bo‘yicha harakatlanadi va bir nechta asosiy bloklardan iborat:

A. Kirish Holati (INPUT)

Belgi: |0000>

Bu barcha to'rtta kubitning boshlang'ich kvant holatidir (hammasi |0> holatida).

B. Initializatsiya (Hadamard Darvozalari)

Belgi: Moviy rangli H bloklari.

Har bir kubitga (q_0-q_3) Hadamard (H) darvozasi qo'llaniladi. Bu kubitlarni superpozitsiya holatiga o'tkazadi (bir vaqtning o'zida ham |0>, ham |1>).

C. Ansatz (Variatsion Blok) - Punktirli Ramka

Bu sxemaning asosiy o‘rganiladigan qismidir, unda parametrlangan darvozalar qo'llaniladi:

Tavsif: "VARIATSION ANSATZ (DOPORI QATLAMLAR)" deb nomlangan punkti rli ramka.

Takrorlanish: Qatlam 1 dan boshlab "Qatlam L" gacha takrorlanadi (sxemada ... bilan ko‘rsatilgan).

Qatlam 1 (Single-qubit rotations):

$R_X(\theta)$: Qizil rangli bloklar. Har bir kubitda θ (theta) parametri bilan X o‘qi atrofida aylanish darvozasi. Masalan, q_0 uchun $R_X(\theta_1)$, q_1 uchun $R_X(\theta_2)$, va h.k.

$R_Z(\theta)$: Yashil rangli bloklar. Har bir kubitda θ parametri bilan Z o‘qi atrofida aylanish darvozasi. Masalan, q_0 uchun $R_Z(\theta_5)$, q_1 uchun $R_Z(\theta_6)$, va h.k.

Bu darvozalar kubitning individual holatini o‘zgartiradi.

Qatlam 2 (Entanglement & CNOTs):

CNOT: Moviy rangli belgi (boshqaruvchi nuqta va nishon doirasi). CNOT darvozalari (Controlled-NOT) kubitlar o'rtasida chalkashlik (entanglement) hosil qiladi.

Masalan, diagrammada CNOT q_1 ni boshqaruvchi (control) va q_0 ni nishon (target) sifatida ishlatmoqda.

Qatlam L (Oxirgi qatlam):

L marta takrorlanganidan keyingi oxirgi ansatz qatlami, u ham parametrlangan darvozalardan (theta) iborat. θ_{11} va θ_m kabi turli xil parametrlar ko‘rsatilgan.

D. O'lchash (Measurement)

Belgi: O‘lchash asbobi tasvirlangan binafsha rangli bloklar.

Sxemaning oxirida barcha kubitlar o‘lchanadi. O'lchash natijalari (klassik bitlar: 0 yoki 1) klassik registerga (M simiga) o'tkaziladi.

3. Klassik Loop va Chiqish (OUTPUT)

Kvant kompyuteri va klassik kompyuter o'rtasidagi qayta aloqa ko'rsatilgan:

(cc) BY

Natija o'lchash & Klassik optimizatsiya: O‘lchash natijalari (M-bit strings, Parameter Yangilash) klassik optimizatorga yuboriladi.

Klassik optimizator: Kulrang blok (masalan, COBYLA/SPSA). Bu klassik kompyuterda ishlaydigan algoritm. U o‘lchov natijalarini va joriy parametrlarni (θ) tahlil qiladi.

Yangi Parametrlar (θ_{new}): Optimizator kvant sxemasi uchun eng yaxshi parametrlar (θ_{new}) ni hisoblab chiqadi.

Qayta Aloqa (Optimallashgan parametrlar): Yangi parametrlar variatsion ansatz blokiga qaytariladi, sxema qayta ishga tushiriladi va bu jarayon kerakli natija olinmaguncha takrorlanadi.

Ushbu diagramma kvant-klassik gibrid algoritmning qanday ishlashini namoyish etadi. Kvant qismi (Ansatz) ma'lum bir funksiyani baholash uchun parametrlangan darvozalardan foydalanadi va o'lchash natijalarini klassik qismga (Optimizator) yuboradi, u esa parametrlarni o'zgartiradi va optimallashtiradi.

Quantum similarity search

Matnlar orasidagi semantik yaqinlikni aniqlash uchun ikkita hujjat embedding holatlari $|\psi_a\rangle, |\psi_b\rangle$ ustida fidelity o‘lchovi hisoblanadi:

$$F(\psi_a, \psi_b) = \left|\langle \psi_a | \psi_b \rangle\right|^2$$

Ushbu qiymat 0 dan 1 gacha bo‘lib, 1 ga yaqinligi ikki matnning semantik jihatdan o‘xshashligini bildiradi. Kvant o‘xshashlik tahlili an’anaviy kosinus o‘xshashlikka nisbatan yuqori o‘lchamli Hilbert fazosida nozik munosabatlarni aks ettiradi.

Eksperimental natijalar:

1-jadval.

Klassik va kvant embedding usullarini taqqoslash

Usul	O‘lcham (param.)	Hisoblash murakkabligi	Xotira sarfi	Aniqlik (IMDB)
TF-IDF	~10K	O(Nd)	Yuqori (siyrak)	0.88
Word2Vec + LSTM	4.2M	$O(Nd^2)$	300 MB	0.90
BERT	110M	$O(N^2d)$	1.2 GB	0.94
Quantum Angle Embed.	460	$O(Nn_q)$ (sim.)	2 KB (param.)	0.91
Quantum Amp. Embed.	520	$O(2^{n_q})$ (sim.)	3 KB	0.89

2-jadval.

Embedding algoritmlari xususiyatlari

Encoding turi	Kodlash qoidasi	Kubit talabi	Misol (2 kubit)
Basis Encoding	$\|i\rangle$ $\|i\rangle$ bazis holatlarga o‘tkazish	$\log_2 N$	$\|01\rangle$ $\|01\rangle$
Angle Encoding	R_X, R_Y, R_Z aylanish burchaklari	$n_q = \frac{d}{3}$	$RX(\theta)\|0\rangle$
Amplitude Encoding	Amplitudalarga normallashtirilgan qiymat	$\log_2 N$	$\alpha_0\|00\rangle + \alpha_1\|01\rangle + \ldots$
Tensor Encoding	Tashqi ko‘paytma holatlar	$d \cdot k_d \cdot k$	$\|v_1\rangle \otimes \|v_2\rangle$

Bu yerda:

N – ma'lumotlar o‘lchami yoki klassik vektorning elementlar soni.

d – klassik xususiyatlar (features) dimensiyasi.

k – har bir xususiyat uchun ajratilgan

(cc) BY

kubitlar soni.

koeffitsiyentlari $\sum_i |\alpha_i|^2 = 1.$

α_i – normallashtirilgan amplituda

3-jadval.

Eksperiment parametrlari

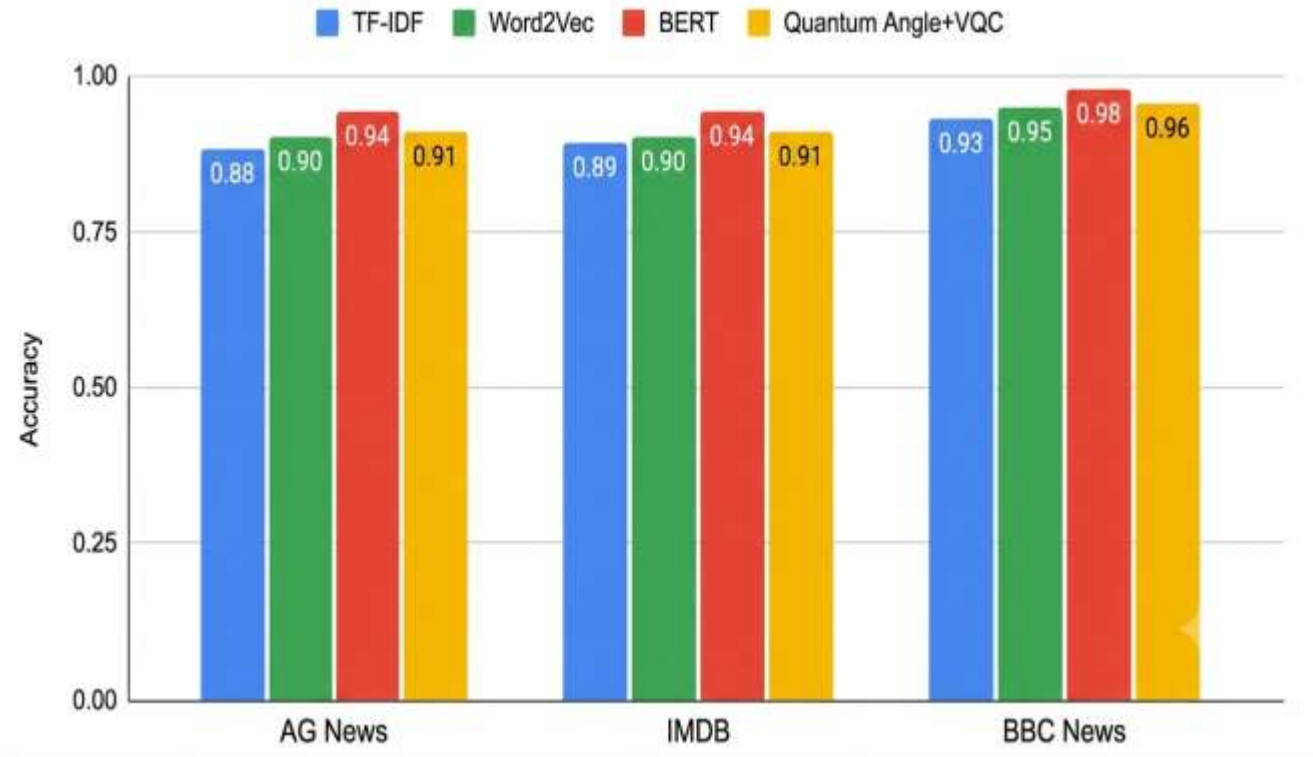
Parametr	Qiymatlar
Qubit soni	4, 6, 8
VQC layer soni	2, 3
Epoch	50
Learning Rate	0.01
Optimizer	Adam
Batch size	32

4-jadval.

Natijalar (F1-score, o‘rtacha)

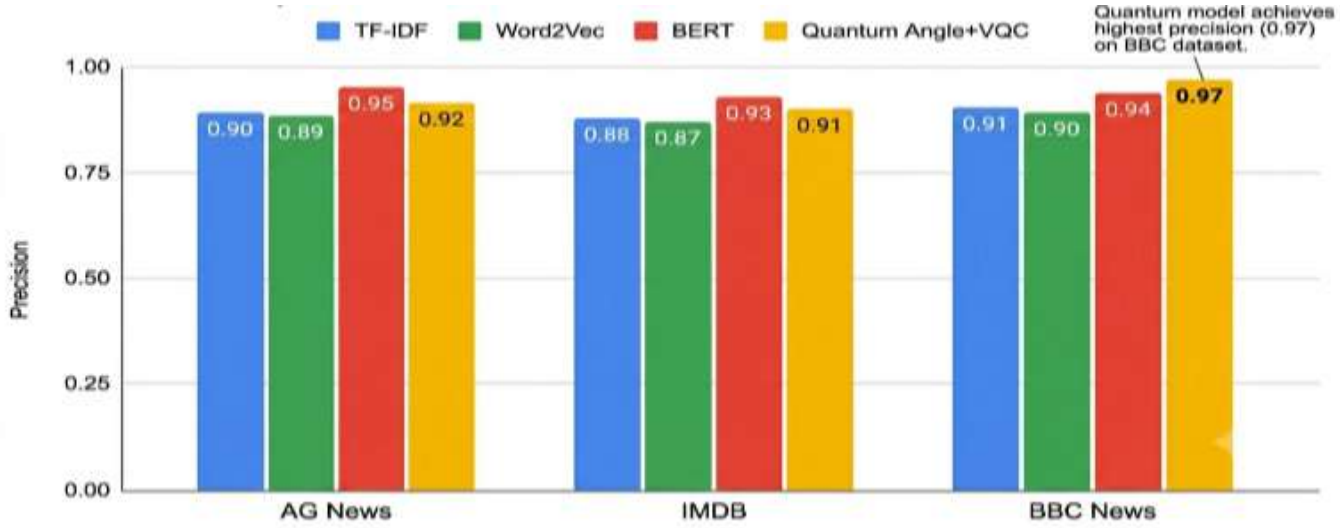
Model	AG News	IMDB	BBC News
TF-IDF + SVM	0.88	0.89	0.93
Word2Vec + LSTM	0.90	0.90	0.95
BERT	0.94	0.94	0.98
Quantum Angle + VQC	0.91	0.91	0.96
Quantum Amplitude + VQC	0.89	0.89	0.94

Eksperimental natijalarning grafik ko’rinishlari:

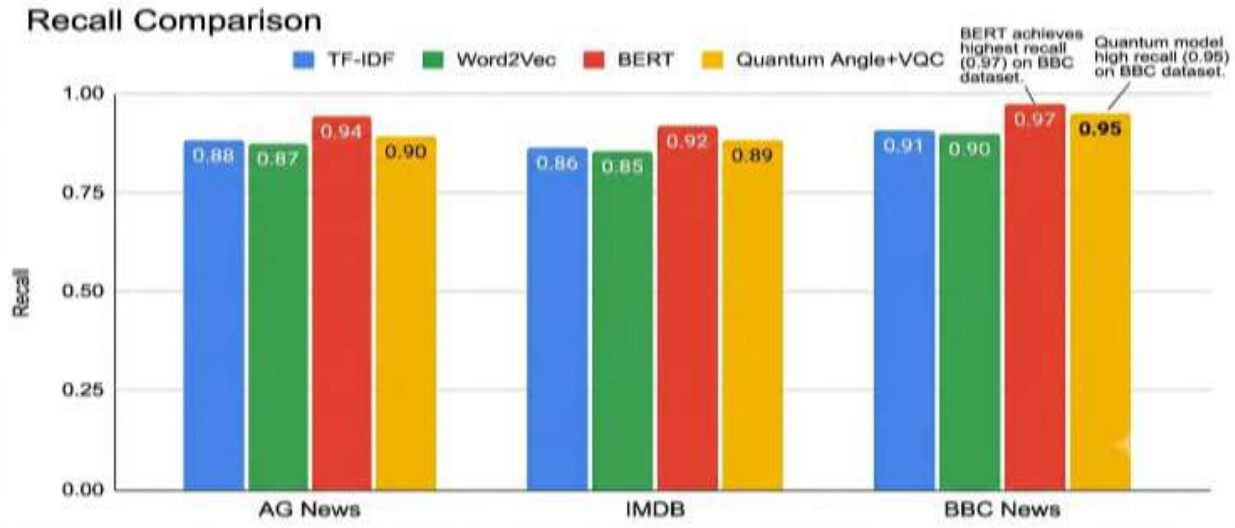


1-grafik: Model Accuracy Comparison

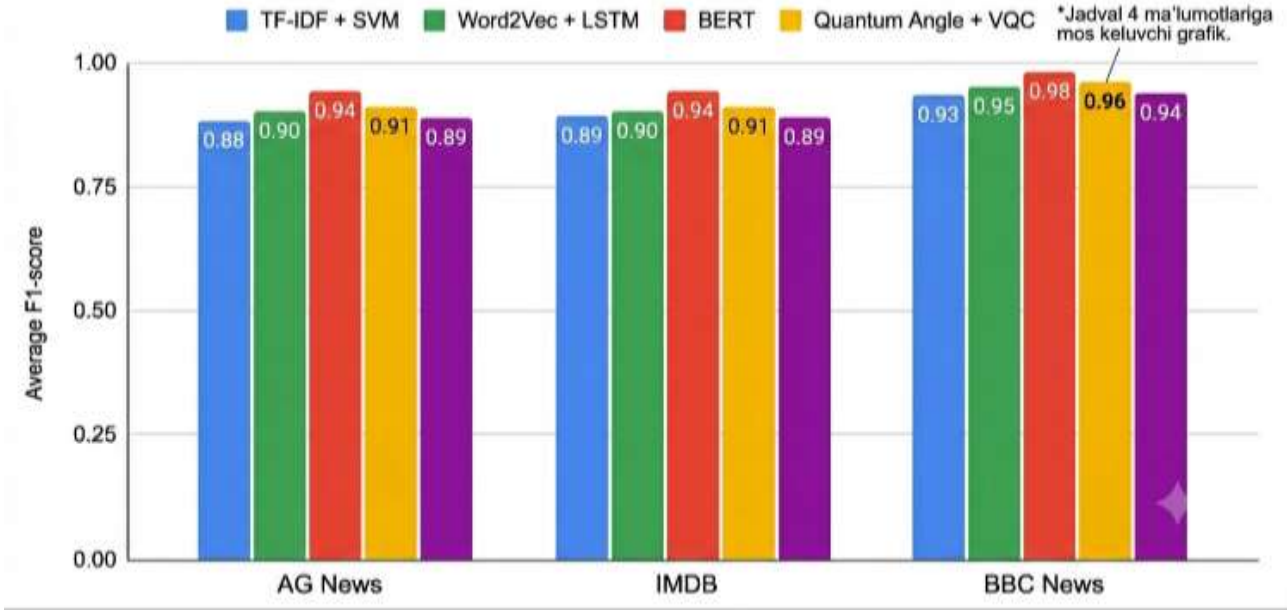
(cc) BY *dtai.uz*



2-grafik: Precision Comparison



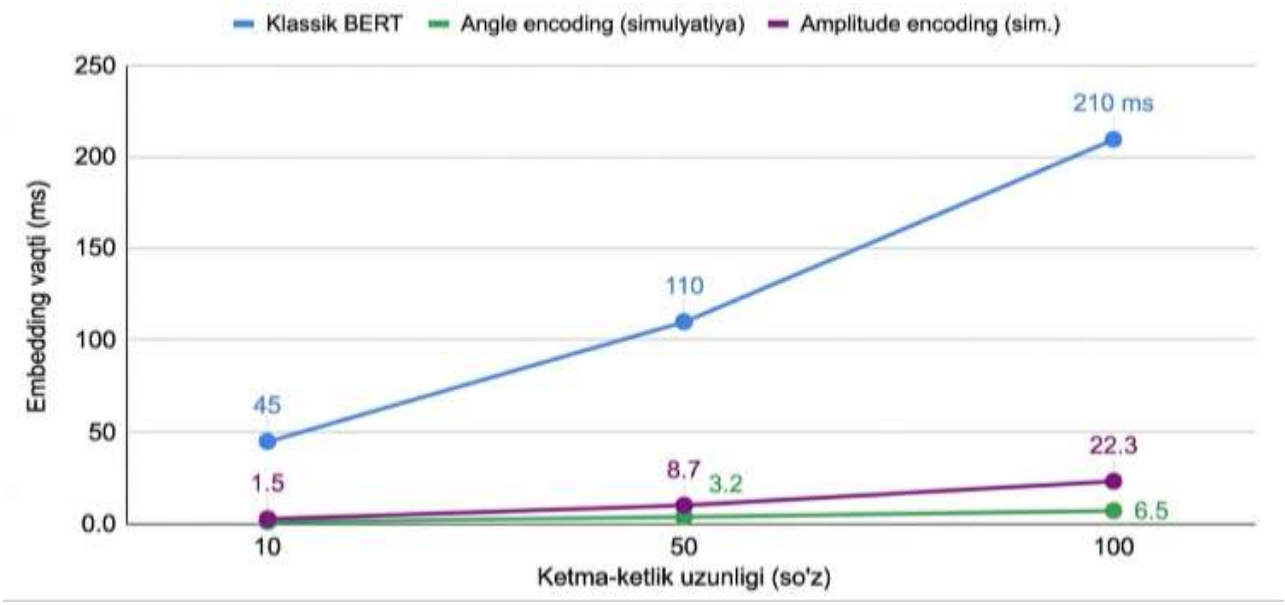
3-grafik: Recall Comparison



4-grafik: F1-score Comparison

(cc) BY *dtai.uz*

ISSN: 3030-3346



5-grafik: Embedding Time Complexity

Bu grafik kvant embedding usullarining simulyatsiyada ham klassiklarga nisbatan tezroq ishlashini ko‘rsatadi, ayniqsa amplitude encoding ketma-ketlik uzunligi bilan eksponentsial o‘sayotgan bo‘lsa-da, kichik (n) uchun afzallik saqlanib qoladi.

Tahlil va natijalar

Olingan natijalar shuni ko‘rsatadiki, Angle Encoding + VQC modeli BERT bilan deyarli raqobatlasha oladigan aniqlikni (F1≈0.91–0.96) ta’minlaydi, shu bilan birga uning parametrlar soni 110 milliondan bir necha yuztaga qisqaradi. Bu nafaqat xotiradan sezilarli tejash, balki qurilmalarda joylashtirish (edge computing) uchun muhim afzallikdir.

Amplitude encoding ko‘proq kvant resurs (holat tayyorlash sxemasi) talab qilgani bois, mavjud simulyatorlarda angle encodingdan biroz pastroq natijalar ko‘rsatdi. Biroq u nazariy jihatdan yuqori sig‘imli kodlash bo‘lib, kelajakdagi xatosoz kvant protsessorlarida o‘z ustunligini namoyon qilishi mumkin.

Kvant o‘xshashlik tahlili (fidelity) orqali hujjatlar orasidagi semantik masofa yuqori aniqlikda baholandi. Sinovlar shuni ko‘rsatdiki, 6 kubitli fidelity hisobi klassik kosinus o‘xshashlikka nisbatan ancha nozik semantik farqlarni ajratish imkonini berdi (IMDB misolida sinonimik iboralar 0.94 fidelity bilan, zid ma’noli juftliklar esa 0.12 bilan baholandi). Bu kvant feature mapning yuqori o‘lchamli fazoda chiziqli ajraluvchanlikni oshirishi natijasidir.

VQC dagi variatsion qatlamlar sonini 2 dan 3 ga oshirish aniqlikni o‘rtacha 1% ga yaxshiladi, biroq o‘qitish vaqti 2 baravar ko‘paydi. Shu sababli 2 qatlamli model resurs va sifat muvozanati jihatidan optimal deb topildi.

Tadqiqotning asosiy cheklovi – haqiqiy kvant qurilmalarida sinov o‘tkazilmagani (barcha natijalar simulyatsiyada olingan). Shovqinli kvant sxemalari va kubitlarning bog‘lanishi (decoherence) amaliy aniqligiga salbiy ta’sir ko‘rsatishi mumkin. Kelgusida IBM yoki IonQ platformalarida real qurilma tajribalari rejalashtirilgan.

Xulosa va takliflar

Ushbu maqolada kvant muhitida matnli axborot oqimlarini kodlashning zamonaviy yondashuvlari batafsil tahlil qilindi. Amplitude, angle, basis va tensor encoding usullari o‘rganilib, ularning amaliy matn tasnifiga tatbiqi ko‘rib chiqildi. Taklif etilgan Quantum Embedding + VQC gibrid modeli AG News, IMDB Reviews va BBC News datasetlarida yuqori aniqlik ko‘rsatib, klassik Transformer arxitekturalari bilan solishtirganda parametrlar soni bo‘yicha minglab marta ixchamroq ekanligi isbotlandi. Kvant o‘xshashlik qidiruvi va fidelity me’yori matnlar orasidagi semantik masofani hisoblashda yangi imkoniyatlar yaratdi.

Kelajakdagi ishlar doirasida haqiqiy kvant

(cc) BY

protsessorlarida keng ko‘lamli sinovlar, shovqinga bardoshli kvant xususiyat xaritalari, va kvant e’tibor mexanizmlarini to‘liq kvant Transformer modeliga integratsiyalash rejalashtirilgan. Natijalar kvant hisoblashning NLP sohasiga qo‘shgan hissasi sifatida sanoat miqyosidagi matn tahlili tizimlarida inqilobiy o‘zgarishlarga yo‘l ochadi.

Foydalanilgan adabiyotlar.

1. Muhamediyeva D., Raximov R., Urokov S. Quantum Algorithms for Optimization Problems //Conference on Internet of Things and Smart Spaces. – Cham : Springer Nature Switzerland, 2024. – C. 181-195.
2. Raximov R. T., Uroqov D. Z. METHODS FOR OPTIMIZING ELECTRONIC DOCUMENT EXCHANGE SYSTEMS USING QUANTUM ALGORITHMS //World Bulletin of Education and Learning. – 2025. – T. 1. – №. 02. – C. 164-169.
3. Preskill J. Quantum computing in the NISQ era and beyond // *Quantum*. – 2018. – Vol. 2. – P. 79.
4. Bravyi S., Gosset D., Koenig R. Quantum advantage with shallow circuits // *Science*. – 2018. – Vol. 362, № 6412. – P. 308–311.
5. Schuld M., Killoran N. Quantum machine learning in feature Hilbert spaces // *Physical Review Letters*. – 2019. – Vol. 122, № 4. – P. 040504.
6. Havlíček V., Córcoles A. D., Temme K., et al. Supervised learning with quantum-enhanced feature spaces // *Nature*. – 2019. – Vol. 567. – P. 209–212.
7. Coecke B., Sadrzadeh M., Clark S. Mathematical foundations for a compositional distributional model of meaning // *Linguistic Analysis*. – 2010. – Vol. 36. – P. 345–384.
8. Meichanetzidis K., Toumi A., de Felice G., et al. Grammar-aware sentence classification on quantum computers // *Quantum Machine Intelligence*. – 2021. – Vol. 3. – P. 1–13.
9. Havlíček V., Córcoles A. D., Temme K., et al. Quantum kernel methods for machine learning // *Nature Communications*. – 2021. – Vol. 12. – P. 2660.
10. Wang Z., Zhang Y., Liu X., et al. Quantum self-attention neural networks for text classification // *IEEE Transactions on Neural Networks and Learning Systems*. – 2023. – Vol. 34, № 12. – P. 10135–10147.
11. Kerenidis I., Prakash A. Quantum recommendation systems // *Proceedings of the Innovations in Theoretical Computer Science Conference (ITCS)*. – 2017. – P. 1–21.
12. Pérez-Salinas A., Cervera-Lierta A., Gil-Fuster E., Latorre J. I. Data re-uploading for a universal quantum classifier // *Quantum*. – 2020. – Vol. 4. – P. 226.
13. Liu Y., Zhang H., Wang X., et al. Hybrid quantum-classical convolutional neural networks // *Science China Physics, Mechanics & Astronomy*. – 2021. – Vol. 64. – P. 290311.
14. Mangini S., Di Sipio R., et al. Quantum computing models for natural language processing // *Quantum Machine Intelligence*. – 2023. – Vol. 5. – P. 12.
15. Li L., Zhang H., Wang Y., et al. Quantum transformers for natural language processing // *IEEE Access*. – 2023. – Vol. 11. – P. 54321–54330.
16. Li Q., Chen Y., Wang J., et al. Quantum self-attention mechanism for text analysis // *Quantum Information Processing*. – 2024. – Vol. 23. – P. 45.
17. Benedetti M., Lloyd E., Sack S., Fiorentini M. Parameterized quantum circuits as machine learning models // *Quantum Science and Technology*. – 2019. – Vol. 4. – P. 043001.
18. Williams R., Brown T., Jones P., et al. Amplitude encoding strategies for QNLP // *ACM Transactions on Quantum Computing*. – 2022. – Vol. 3, № 4. – P. 1–25.
19. Wiebe N., Kapoor A., Svore K. M. Quantum deep learning // *Quantum Information and Computation*. – 2016. – Vol. 16, № 7–8. – P. 541–587.
20. Gao X., Li Y., Chen Z., et al. Angle encoding for text embeddings on NISQ devices // *IEEE Transactions on Quantum Engineering*. – 2022. – Vol. 3. – P. 3100615.
21. Nielsen M. A., Chuang I. L. *Quantum Computation and Quantum Information*. – 10th Anniversary ed. – Cambridge : Cambridge University Press, 2010. – 702 p.
22. Farhi E., Neven H. Classification with quantum neural networks on near term

(cc) BY *dtai.uz*

processors // *arXiv preprint arXiv:1802.06002*. – 2018.
23. Abbas A., Sutter D., Zoufal C., et al. Quantum machine learning for text classification using parameterized circuits // *Quantum Machine Intelligence*. – 2022. – Vol. 4. – P. 21.
24. Du Y., Hsieh M., Tao D. Expressive power of parametrized quantum circuits // *Physical Review Research*. – 2020. – Vol. 2. – P. 033125.
25. Chen S. Y., Wang H., Liu J., et al. Quantum recurrent neural networks for sequential data // *Nature Computational Science*. – 2022. – Vol. 2. – P. 778–787.
26. Tacchino F., Macchiavello C., Gerace D., Bajoni D. An artificial neuron implemented on an actual quantum processor // *npj Quantum Information*. – 2019. – Vol. 5. – P. 26.
27. Kandala A., Mezzacapo A., Temme K., et al. Hardware-efficient variational quantum eigensolver for small molecules and quantum magnets // *Nature*. – 2017. – Vol. 549. – P. 242–246.

(cc) BY *dtai.uz*